



UNIVERSIDADE ESTADUAL PAULISTA  
“JÚLIO DE MESQUITA FILHO”  
Campus de São José do Rio Preto

---

María Jacqueline Atoche Bravo

*Análise do Descritor de Padrões Mapeados  
Localmente em Multiescala para Classificação de  
Textura em Imagens Digitais*

Dissertação de Mestrado  
Pós-Graduação em Matemática

---

Instituto de Biociências, Letras e Ciências Exatas  
Rua Cristóvão Colombo, 2265, 15054-000  
São José do Rio Preto - SP - Brasil  
Telefone: (17) 3221-2444 - Fax: (17) 3221-2445

María Jacqueline Atoche Bravo

*Análise do Descritor de Padrões Mapeados  
Localmente em Multiescala para  
Classificação de Textura em Imagens  
Digitais*

Orientador:  
Prof. Dr. Maurílio Boaventura

UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”  
INSTITUTO DE BIOCIÊNCIAS, LETRAS E CIÊNCIAS EXATAS  
CAMPUS DE SÃO JOSÉ DO RIO PRETO

São José do Rio Preto

31 de Março de 2016

Atoche Bravo, María Jacqueline.

Análise do Descritor de Padrões Mapeados Localmente em Multiescala para Classificação de Textura em Imagens Digitais / María Jacqueline Atoche Bravo. – São José do Rio Preto, 2016

155 f. : il.

Orientador: Maurilio Boaventura

Dissertação (mestrado) - Universidade Estadual Paulista “Júlio de Mesquita Filho”, Instituto de Biociências, Letras e Ciências Exatas

1. Computação - Matemática. 2. Modelos matemáticos. 3. Processamento de imagens - Técnicas digitais. 4. Reconhecimento de padrões. I. Boaventura, Maurílio. II. Universidade Estadual Paulista “Júlio de Mesquita Filho”, Instituto de Biociências, Letras e Ciências Exatas. III. Título.

CDU - 518.72

Ficha catalográfica elaborada pela Biblioteca do IBILCE  
UNESP - Câmpus de São José do Rio Preto

María Jacqueline Atoche Bravo

*Análise do Descritor de Padrões Mapeados Localmente em Multiescala  
para Classificação de Textura em Imagens Digitais*

Dissertação apresentada ao Programa de Pós-Graduação em Matemática, da Universidade Estadual Paulista “Júlio de Mesquita Filho”, como parte dos requisitos para a obtenção do título de Mestre em Matemática, área de concentração: Modelagem Matemática.

BANCA EXAMINADORA

---

Prof. Dr. Maurilio Boaventura  
UNESP - São José do Rio Preto  
Orientador

---

Prof. Dr. Marcos William Da Silva Oliveira  
Instituto Federal de São Paulo

---

Prof. Dr. Evanivaldo Castro Silva Júnior  
Faculdade de Tecnologia de São José do Rio  
Preto - FATEC

São José do Rio Preto, 31 de Março de 2016.

Aos meus pais, os grandes amores da minha vida.

A minha querida irmã Magdalena.

*Dedico.*

## AGRADECIMENTOS

Gostaria de agradecer a todos que, de alguma maneira, contribuíram para que este trabalho pudesse ser realizado. Em especial agradeço:

Primeiramente à Deus por esta oportunidade, por permitir minha chegada até aqui.

Ao meu professor, orientador Maurílio Boaventura pelos ensinamentos, pela dedicação, sugestões, correções e pela infinita paciência na elaboração desta Dissertação.

A toda minha família, principalmente aos meus pais, Gloria e Nelson, pelo seu imenso amor que recebo todos os dias, pela compreensão e carinho em todos os momentos difíceis, pelo apoio em minhas decisões. À minha querida irmã Magdalena, por todos os conselhos. Ainda que estando longe, me deram apoio, incentivo, me animaram sempre a seguir.

A todos meus amigos, que sempre acreditaram em mim, que me incentivaram no decorrer deste trabalho.

Aos funcionários do DMAP, que direta ou indiretamente, contribuíram para a elaboração deste trabalho, em especial aos técnicos Getúlio e Tiago pela ajuda.

Ao CNPq, pelo auxílio financeiro.

Hoje é sempre o dia certo  
de fazer as coisas certas,  
de maneira certa.  
Amanhã será tarde.  
*Martin Luther King*

No presente trabalho, apresenta-se uma revisão sobre os principais abordagens para análise e classificação de texturas, entre eles o descritor LBP (*Local Binary Pattern*), o descritor LFP (*Local Fuzzy Pattern*) e o descritor MSLMP (*Multi-scale Local Mapped Pattern*), o qual é uma extensão multiescalar do descritor LMP (*Local Mapped Pattern*). Resultados anteriores presentes na literatura, indicaram que o MSLMP conseguiu resultados superiores aos mencionados anteriormente. Neste trabalho propõe-se uma análise mais abrangente sobre sua viabilidade para concluir que o MSLMP é mais eficaz que os anteriores. Essa análise é feita alterando-se a Matriz de Pesos para os pixels limiarizados. Para avaliar seu desempenho, foi utilizada a base de texturas do Album de Brodatz. Após processá-la pelo descritor MSLMP, com cada uma das matrizes de Pesos propostas neste trabalho, foram comparadas as taxas de acertos alcançadas usando a distância Chi-quadrado. Resultados experimentais mostram um valor de sensibilidade melhor para o descritor MSLMP em comparação aos outros descritores presentes na literatura.

**Palavras-chave:** Visão computacional, Análise de textura, Padrão Mapeado Localmente em Multiescala (MSLMP), Classificação de texturas.

---

## ABSTRACT

This work, presents a review about the main techniques for analysis and classification of textures, including the LBP descriptor (Local Binary Pattern), the descriptor LFP (Local Fuzzy Pattern) and the descriptor MSLMP (Multi-Scale Local Mapped Pattern), which is a multi-scale extension of the LMP method (Local Mapped Pattern). Previous results present in the literature, indicated that the MSLMP achieved better results than those mentioned above. This work proposes a more comprehensive analysis of its feasibility to conclude that this descriptor is more effective than the others. This analysis is done by changing the weight matrix for the thresholding pixels. To evaluate its performance, it was used the texture base of the Brodatz album. After processing it by the descriptor MSLMP with each of the weights matrices proposed in this work, the achieved hit rates were compared by using the distance Chi-square. Experimental results show a better sensitivity value for MSLMP descriptor in comparison of other descriptors present in the literature.

**Keywords:** Computational vision, Texture analysis, Multi-scale Local Mapped Pattern (MSLMP), Texture classification.

## LISTA DE FIGURAS

Figura 1.1	Etapas de um sistema de visão computacional . . . . .	17
Figura 1.2	Representação de uma imagem digital. Fonte (CAVALCANTE, 2019)	18
Figura 2.1	Exemplos de texturas com padrões repetitivos e não repetitivos. . .	23
Figura 2.2	Alguns tipos de características visuais de textura. Fonte (BRO-DATZ, 1966) . . . . .	26
Figura 2.3	Exemplos de texturas artificiais. Fonte (PRATT, 1991) . . . . .	27
Figura 2.4	Exemplos de texturas naturais. Fonte (PRATT, 1991) . . . . .	27
Figura 2.5	Classificador Distância Mínima. Fonte (NASCIMENTO, 2003) . . .	30
Figura 2.6	Separação de dados em um espaço bidimensional. Fonte (CORTES; VAPNIK, 1995) . . . . .	30
Figura 2.7	Classificador $K$ -vizinhos mais próximos. Fonte (MARTINS et al., 2005) . . . . .	31
Figura 2.8	Exemplos de alguns métodos de segmentação de texturas: (a) Fonte (DENG; MANJUNATH, 2001), (b) Fonte (ALLILI; ZIOU, 2007) . . . . .	33
Figura 2.9	Alguns exemplos de síntese de texturas. Fonte (WEI; LEVOY, 2000)	35
Figura 2.10	Diagrama típico de sistemas CBIR. Fonte (SMEULDERS et al., 2000)	36
Figura 2.11	Exemplo de um sistema CBIR. Fonte (LEMOS; REIS; OLIVEIRA, 2000) . . . . .	37
Figura 3.1	Conversão da vizinhança em <i>Texture Unit</i> . . . . .	42

Figura 3.2	Cálculo do <i>Texture Unit</i> . Fonte (TRAVAINI, 2015) . . . . .	43
Figura 3.3	Conjuntos de vizinhanças circulares simétricas (MÄENPÄÄ; PIETIKÄINEN, 2003). . . . .	45
Figura 3.4	Cálculo do <i>Local Binary Pattern</i> . Fonte (TRAVAINI, 2015) . . . . .	46
Figura 3.5	Geração de um código LFP. Fonte (TRAVAINI, 2015) . . . . .	48
Figura 3.6	Cálculo do código LFP. Fonte (VIERA, 2013) . . . . .	49
Figura 3.7	Cálculo do mapeamento relativo do pixel central. Fonte (CONTRE-RAS; BOAVENTURA; BOAVENTURA, 2015) . . . . .	50
Figura 3.8	Funções de Mapeamento do nível de cinza pela Equação 3.8. Fonte (FERRAZ; PEREIRA; GONZAGA, 2014) . . . . .	52
Figura 4.1	Vizinhanças circular de um pixel em multiescala. Fonte (OJALA; PIETIKÄINEN; MÄENPÄÄ, 2002). . . . .	55
Figura 4.2	Exemplo do cálculo do MSLBP2 de uma matriz $9 \times 9$ : (a) Matriz $9 \times 9$ , (b) Média das regiões $3 \times 3$ da matriz original, (c): cálculo do MSLBP2	56
Figura 4.3	Distribuição ótima dos raios do padrão MSLBP1 com respeito à redução de redundância da informação capturada pelo padrão. Fonte: (MÄENPÄÄ; PIETIKÄINEN, 2003) . . . . .	57
Figura 5.1	Texturas presentes no álbum de Brodatz . . . . .	69
Figura 5.2	Processo de classificação . . . . .	70

## LISTA DE TABELAS

Tabela 2.1	Matriz de confusão de duas classes. Fonte (BAGESTEIRO, 2015)	32
Tabela 2.2	Matriz de confusão de cinco classes	33
Tabela 5.1	Sensibilidade obtida a partir de diversos descritores presentes na literatura. Fonte (CONTRERAS; BOAVENTURA; BOAVENTURA, 2015)	71
Tabela 5.2	Sensibilidade obtida ao testar o descritor MSLMP1	72
Tabela 5.3	Ganho de sensibilidade do descritor MSLMP1	73
Tabela 5.4	Parâmetros otimizados $\lambda$ da função de mapeamento	74
Tabela 5.5	Sensibilidade obtida ao testar o descritor MSLMP2	74
Tabela 5.6	Parâmetros otimizados $\lambda$ da função de mapeamento	74
Tabela 5.7	Ganho de sensibilidade do descritor MSLMP2	75
Tabela 5.8	Sensibilidade obtida ao testar o descritor MSLMP3	75
Tabela 5.9	Parâmetros otimizados $\lambda$ da função de mapeamento	75
Tabela 5.10	Ganho de sensibilidade do descritor MSLMP3	75
Tabela 5.11	Sensibilidade obtida ao testar o MSLMP4	76
Tabela 5.12	Parâmetros otimizados $\lambda$ da função de mapeamento	76
Tabela 5.13	Ganho de sensibilidade do descritor MSLMP4	76
Tabela 5.14	Sensibilidade obtida ao testar o descritor MSMLP5	76
Tabela 5.15	Parâmetros otimizados $\lambda$ da função de mapeamento	77

Tabela 5.16	Ganho de sensibilidade do descritor MSLMP5 . . . . .	77
Tabela 5.17	Sensibilidade obtida ao testar o descritor MSMLP6 . . . . .	77
Tabela 5.18	Parâmetros otimizados $\lambda$ da função de mapeamento . . . . .	77
Tabela 5.19	Ganho de sensibilidade do descritor MSLMP6 . . . . .	77
Tabela 5.20	Comparacao dos descritores MSLMP's . . . . .	78

<b>1</b>	<b>Introdução</b>	<b>16</b>
1.1	Motivação . . . . .	20
1.2	Objetivos . . . . .	21
1.3	Estrutura do trabalho . . . . .	21
<b>2</b>	<b>Fundamentação Teórica</b>	<b>22</b>
2.1	Introdução . . . . .	22
2.2	Textura . . . . .	24
2.2.1	Tipos de Classificação das Texturas . . . . .	27
2.3	Aplicações da textura . . . . .	28
2.3.1	Classificação de textura . . . . .	28
2.3.1.1	Classificadores . . . . .	29
2.3.1.2	Métricas para avaliar os classificadores . . . . .	31
2.3.2	Segmentação de textura . . . . .	33
2.3.3	Percepção de Forma a partir de textura . . . . .	34
2.3.4	Síntese de Textura . . . . .	34
2.3.5	Recuperação de imagens por conteúdo . . . . .	35

2.4	Abordagens para descrição de textura . . . . .	37
2.4.1	Abordagem estatística . . . . .	38
2.4.2	Abordagem estrutural (ou geométrica) . . . . .	39
2.4.3	Abordagem espectral . . . . .	39
2.5	Considerações Finais . . . . .	40
<b>3</b>	<b>Descritores de Textura</b>	<b>41</b>
3.1	Texture Unit (TU) . . . . .	41
3.2	Local Binary Pattern (LBP) . . . . .	43
3.3	Local Fuzzy Pattern (LFP) . . . . .	47
3.4	Local Mapped Pattern (LMP) . . . . .	50
3.5	Considerações finais . . . . .	52
<b>4</b>	<b>Padrões em Multiescala</b>	<b>54</b>
4.1	O Multi-Scale Local Binary Pattern (MSLBP) . . . . .	54
4.2	Multi-Scale Local Mapped Pattern (MSLMP) . . . . .	58
4.3	Extração de características . . . . .	60
4.3.1	Matrizes de Pesos utilizadas para o teste do método . . . . .	61
4.4	Considerações finais . . . . .	67
<b>5</b>	<b>Resultados Experimentais</b>	<b>68</b>
5.1	Base de dados . . . . .	68
5.2	Processo de avaliação e classificação . . . . .	69
5.3	Resultados obtidos . . . . .	71
5.4	Considerações finais . . . . .	78
<b>6</b>	<b>Conclusões</b>	<b>79</b>
6.1	Sugestões para trabalhos futuros . . . . .	79

<b>Referências Bibliográficas</b>	<b>81</b>
<b>A Programação no Matlab</b>	<b>87</b>
A.1 Rotina para o cálculo do MSLMP1 . . . . .	87
A.2 Rotina para o cálculo do MSLMP2 . . . . .	89
A.3 Rotina para o cálculo do MSLMP3 . . . . .	90
A.4 Rotina para o cálculo do MSLMP4 . . . . .	91
A.5 Rotina para o cálculo do MSLMP5 . . . . .	93
A.6 Rotina para o cálculo do MSLMP6 . . . . .	94
<b>B Sensibilidade obtida do MSLMP com respeito à matriz de Pesos 4.11</b>	<b>96</b>
<b>C Sensibilidade obtida do MSLMP com respeito à matriz de Pesos 4.12</b>	<b>106</b>
<b>D Sensibilidade obtida do MSLMP com respeito à matriz de Pesos 4.13</b>	<b>116</b>
<b>E Sensibilidade obtida do MSLMP com respeito à matriz de Pesos 4.14</b>	<b>126</b>
<b>F Sensibilidade obtida do MSLMP com respeito à matriz de Pesos 4.15</b>	<b>136</b>
<b>G Sensibilidade obtida do MSLMP com respeito à matriz de Pesos 4.16</b>	<b>146</b>

# CAPÍTULO 1

## INTRODUÇÃO

Os seres humanos têm a capacidade de distinguir diferentes objetos apenas ao observá-los. Uma pessoa, basta olhar uma árvore para notar que seu tronco é rugoso, ou olhar um tecido para perceber se é liso ou áspero. A visão é um dos sentidos mais importantes dos seres humanos, por prover a uma pessoa informações sobre o ambiente ao seu redor. Devido ao crescente avanço da ciência e da tecnologia, diferentes métodos vêm sendo desenvolvidos para a construção de sistemas artificiais destinados a incorporar a percepção de um ambiente por uma máquina, por meio do processamento de informações visuais. O reconhecimento de objetos é uma das aplicações que envolve um sistema de visão computacional. A visão computacional procura se assemelhar à visão humana, a partir de uma imagem de entrada, a saída é uma interpretação dela como um todo, ou pelo menos parcialmente.

Em outras palavras, visão computacional é a área de estudo responsável, pela forma como um computador enxerga o meio à sua volta, extraindo dados informativos significativos a partir de imagens capturadas por câmeras de vídeo, sensores, scanners, entre outros dispositivos. Geralmente são desenvolvidos algoritmos computacionais que buscam automatizar determinadas tarefas associadas à visão humana. Estas informações permitem reconhecer, manipular e pensar sobre os objetos que compõem uma imagem (BALLARD; BROWN, 1982).

Um sistema de visão computacional é composto por uma série de etapas que tratam de simular a visão humana, as quais são: aquisição da imagem, pré-processamento, segmentação, seleção de características, reconhecimento e classificação. Essas etapas encontram-se

sintetizadas na Figura 1.1.




Figura 1.1: Etapas de um sistema de visão computacional

A primeira etapa de um sistema de visão computacional é a aquisição da imagem, a qual consiste em digitalizar uma cena, a partir de uma câmera ou outro aparelho capaz de captura-la. A etapa de pré-processamento, envolve passos como por exemplo a filtragem de ruídos, a qual é utilizada para aprimorar a qualidade de uma imagem, corrigindo iluminação, contraste, distorções e nitidez. Após estas etapas, as imagens são submetidas à segmentação, que consiste em dividir a imagem em regiões que distinguem os objetos de interesse que estão contidos nessas imagens. A partir de imagens já segmentadas busca-se obter dados relevantes ou atributos, das regiões ou objetos destacados. Essas características correspondem as informações de interesse do sistema. A partir dessas características, é possível identificar a qual classe ou grupo esse objeto pertence e então seja classificado em uma base de imagens.

Apesar de que as etapas exibidas anteriormente (Figura 1.1) estejam relacionadas e em sequência, elas são independentes, é dizer que alguns problemas podem apenas utilizar algumas delas.

As imagens digitais são os objetos de estudo em visão computacional. Qualquer imagem digital pode ser representada por uma função bidimensional  $f(x, y)$ , onde  $x$  e  $y$  denotam as coordenadas espaciais e o valor de  $f$  em qualquer ponto  $(x, y)$  é proporcional à intensidade luminosa (brilho ou nível de cinza) (GONZALEZ; WOODS, 2002). Utilizando um computador, realiza-se a amostragem dessas imagens, onde as amostras são igualmente espaçadas e arranjadas na forma de uma matriz  $N \times M$ , com cada elemento sendo uma quantidade discreta. Cada elemento que compõe essa matriz é chamado de pixel (*picture element*), o qual é o menor elemento de uma imagem digital (CAVALCANTE, 2019).

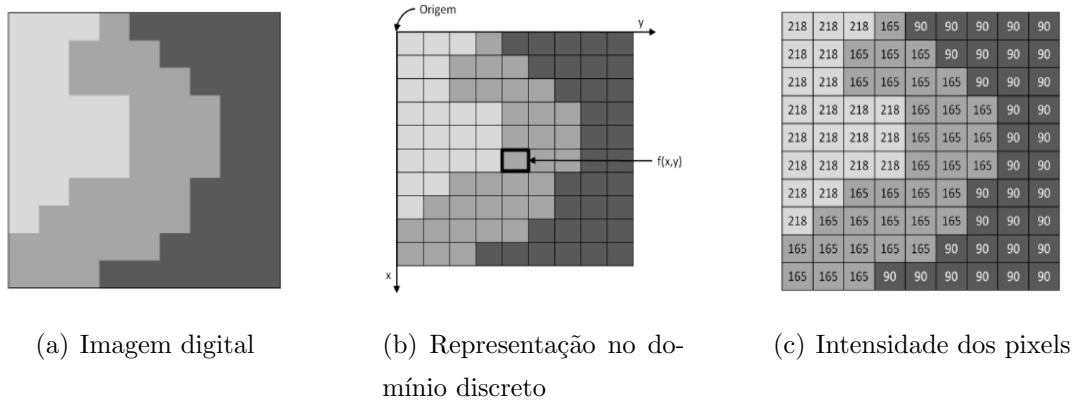


Figura 1.2: Representação de uma imagem digital. Fonte (CAVALCANTE, 2019)

Na Figura 1.2 observa-se: em (a) uma imagem em seu formato digital; em (b) a identificação dos eixos para discretização da imagem; e em (c) a representação numérica dos tons de cinza.

Visão computacional é uma importante área de pesquisa, pois tem diferentes aplicações em diversas áreas do conhecimento, como:

- medicina: diagnósticos médicos podem ser auxiliados pela análise de imagens médicas, capturadas através de ressonância magnética, tomografia computadorizada ou ultrassonografia; das quais informações podem ser extraídas, permitindo realizar melhores diagnósticos sobre os pacientes (KHADEMI; KRISHNAN, 2008; CHANG; ZHANG; LIU, 2011);
- sensoriamento remoto: fotografias aéreas devem ser avaliadas para a obtenção rápida de mapas cartográficos e estudos geográficos, tais como, análise do solo, mapeamento de áreas florestais e áreas urbanas (RIGNOT; KWOK, 1990);
- biometria: área que estuda a autenticação de um indivíduo a partir de análise de características físicas ou comportamentais, como, por exemplo, impressões digitais, modo de caminhar ou através da face (JIA et al., 2014; AHONEN; HADID; PIETIKÄINEN, 2006; JIA et al., 2013);
- inspeção automática, controle de qualidade: pela utilização de câmeras especiais, pode ser verificada a qualidade de artefatos ou a busca de defeitos (JAIN; FARROKHIA; ALMAN, 1990; DEWAELE; GOOL; OOSTERLINCK, 1988);
- microscopia: análise de imagens capturadas por meio de microscópicos ópticos ou

eletrônicos, variando desde a biologia até a metalurgia, identificando e classificando células ou partículas (FORTEY, 1995);

- captura de movimentos: muito utilizado nos efeitos especiais em filmes, o movimento de atores é capturado por várias câmeras e posteriormente aplicado a um avatar eletrônico.

Dentre as informações visuais que podem ser extraídas de uma imagem, a textura é a característica visual mais importante para identificação de estruturas homogêneas, pois suas propriedades representam a superfície ou estrutura de um objeto (SONKA; HLAVAC; BOYLE, 2008). Uma importante área de pesquisa em visão computacional é a análise de texturas, a qual tem por objetivo estudar as propriedades da superfície de um objeto, compreender como os seres humanos distinguem diferentes texturas e modelar algoritmos que tenham a capacidade de diferenciá-las. A textura é uma importante característica ou propriedade para a análise de imagens digitais, pois proporciona dados para seu reconhecimento e interpretação (CHOI et al., 2002).

Os estudos que envolvem a análise de texturas se estendem por mais de cinco décadas, entretanto, segue sendo tema de muito interesse. Em parte, as pesquisas são incentivadas pela grande quantidade de texturas presentes na natureza e pela boa capacidade do sistema visual humano em identificá-las ou analisá-las. Estudos mostram um fato interessante, de como a imagem na retina é decomposta pelo cérebro em vários canais de frequências espacialmente orientadas (VALOIS; ALBRECHT; THORELL, 1982).

As texturas estão bastantes presentes na natureza e nos diferentes objetos encontrados no seu redor. Seu conceito depende do contexto em que está inserida e a qual tipo de aplicação está associada. Desta maneira é impossível estabelecer uma única definição formal do conceito de textura. De modo geral, a textura está relacionada às áreas descritas acima e em numerosas outras. A textura proporciona informações sobre a distribuição espacial das variações de tonalidade de um objeto ou da repetição tonal de alguns grupos de objetos não identificáveis individualmente (HARALICK; SHANMUGAM; DINSTEN, 1973). A textura descreve a forma, tamanho, sombra e tonalidade de cada objeto, permitindo a impressão visual de rugosidade ou suavidade de determinada superfície (GONZALEZ; WOODS, 2002).

Dentre as principais aplicações da análise de texturas estão a **classificação**, a qual refere-se à identificação de cada imagem, de um banco de dados de imagens, a um rótulo ou classe. Esse conjunto de classes pode ou não ser definido previamente, por meio de um

conjunto de treinamento, sobre a qual se tem como exemplo os trabalhos de Ahonen, Hadid e Pietikäinen (2006) e Zhao e Pietikäinen (2007); a **segmentação**, que tem como objetivo particionar a imagem em regiões que apresentem características semelhantes (ZULIANG; LIMIN; JIANTING, 2012); e finalmente, a **síntese** de texturas, responsável pela determinação de um modelo capaz de reproduzir uma dada textura a partir de uma amostra inicial (XU; MA, 2010).

A maioria das abordagens para classificação de texturas assume, que as amostras desconhecidas a serem classificadas são idênticas ao conjunto de amostras utilizadas para treinar o classificador, com relação à escala espacial, orientação e propriedades da escala de cinza (OJALA; PIETIKÄINEN; MÄENPÄÄ, 2002). Tendo em vista a subjetividade inerente à textura, vários métodos responsáveis por descrever suas particularidades foram desenvolvidos e introduzidos ao longo dos anos, entre eles o Padrão Mapeado Localmente em Multiescala (*Multi-scale Local Mapped Pattern* (MSLMP)) (CONTRERAS; BOAVENTURA; BOAVENTURA, 2015), o qual consiste de uma versão estendida do micropadrão local conhecido como Padrão Mapeado Localmente (*Local Mapped Pattern* (LMP)) proposto por Ferraz, Pereira e Gonzaga (2014), através do qual realiza-se o mapeamento local do padrão representado pela vizinhança  $3 \times 3$  de um pixel. O descritor MSMLP trata de extrações sucessivas do LMP considera vizinhanças de tamanho variável neste cálculo.

## 1.1 Motivação

Como já foi dito anteriormente uma importante característica de baixo nível, utilizada tanto na percepção humana quanto no reconhecimento de padrões, é a textura. Por tal motivo foram desenvolvidos ferramentas computacionalmente que descrevem as características de uma textura (TOBIAS et al., 1996). A conveniência de automatizar a inspeção visual em diversas áreas, aumentou significativamente nos últimos anos. O funcionamento da inspeção humana é geralmente ineficaz para processos que necessitam de precisão e velocidade de identificação, devido a grande quantidade de informações visuais.

Diferentes descritores foram utilizados para descrever uma imagem computacionalmente, pois é desejado que um descritor seja robusto para a classificação de textura, utilizando seus níveis de cinza. O *Local Fuzzy Pattern* (LFP) e o *Multi-Scale Local Mapped Pattern* (MSLMP) apresentaram resultados favoráveis neste sentido (VIERA, 2013; CONTRERAS; BOAVENTURA; BOAVENTURA, 2015). Mas, o número de estudos sobre a avaliação do desempenho desses descritores, ainda é pequeno. Estudos existentes

comparam poucos métodos ou utilizam um pequeno número de amostras para tentar chegar a conclusões significativas.

Assim, a principal motivação para este trabalho é realizar uma comparação do MSLMP alterando-se a Matriz de Pesos, afim de avaliar seu desempenho em relação a outros descritores presentes na literatura.

## 1.2 Objetivos

O presente trabalho tem como objetivo geral, analisar a variabilidade do descritor *Multi-scale Local Mapped Pattern* aplicado ao problema de classificação de texturas. Essa variação será feita através da mudança da Matriz de Pesos deste descritor. Essa metodologia é avaliada e testada através de experimentos utilizando-se amostras de imagens contidas na base do Álbum de Brodatz (BRODATZ, 1966), e por fim são comparados aos resultados do estado da arte na literatura científica.

## 1.3 Estrutura do trabalho

Estruturalmente, este trabalho está dividido em 6 capítulos.

No capítulo 1 é apresentada uma introdução sobre os aspectos gerais do assunto abordado neste trabalho, bem como a motivação, objetivos e organização desta dissertação.

No capítulo 2 é apresentada uma revisão das definições de textura, assim como métodos de classificação e suas principais aplicações e as principais abordagens utilizadas para descreve-las.

No capítulo 3 são apresentados os principais descritores de texturas presentes na literatura, entre eles o *Texture Unit* (TU), o *Local Binary Pattern* (LBP), o *Local Fuzzy Pattern* (LFP) e o *Local Mapped Pattern* (LMP).

No capítulo 4 são apresentados o descritor estudado *Multi-scale Local Mapped Pattern* e a forma avaliativa do desempenho do descritor MSLMP para a classificação de amostras de texturas, mudando-se a matriz de Pesos.

No capítulo 5 são apresentados e discutidos os resultados obtidos.

Finalmente, no capítulo 6 são apresentadas as conclusões finais e são dadas algumas diretrizes para futuros trabalhos.

## CAPÍTULO 2

# FUNDAMENTAÇÃO TEÓRICA

A análise de texturas é uma importante área de pesquisa em visão computacional. No entanto, é um problema de difícil resolução devido principalmente à diversidade ou complexidade das texturas naturais. Muitas pesquisas têm sido realizadas a fim de definir computacionalmente as características que descrevem um objeto por meio de suas características texturais.


A utilização da análise de texturas se apresenta como uma abordagem apropriada para a descrição, de maneira efetiva, de cada região contida em uma imagem, contribuindo para uma melhoria no desempenho em um processo de classificação. Esta constitui uma das tarefas mais complexas presentes na análise de imagens. Desse modo, é utilizada em processos de alto nível e sua aplicação abrange diversas áreas do conhecimento.

### 2.1 Introdução

A análise de imagens por meio de texturas vêm sendo utilizada para diferenciar diversos tipos de estruturas encontrados na natureza. Além disso, é uma das características mais significantes para classificar e identificar objetos, proporcionando uma chave para compreender os mecanismos básicos que fundamentam a percepção visual humana. Estudos afirmam que, a análise de textura é utilizada em diversas aplicações que variam desde a análise de imagens aéreas ou de satélite, imagens geológicas (HARALICK; SHANMUGAM; DINSTEIN, 1973), sensoriamento remoto (HARALICK; SHANMUGAM; DINSTEIN, 1973), inspeção (DEWAELE; GOOL; OOSTERLINCK, 1988), diagnóstico em

imagens médicas (LIU et al., 2010), ou até mesmo no processamento de documentos (JAIN; BHATTACHARJEE; CHEN, 1992). A análise de imagens médicas, tem um papel fundamental na obtenção de diagnósticos mais precisos, como por exemplo na caracterização de lesões cervicais (JI; ENGEL; CRAINE, 2000), na detecção e avaliação do mal de Alzheimer em imagens de ressonância magnética (BURRILL, 1999), no estudo de microcalcificações e regiões suspeitas em mamografias (GUPTA; UNDRILL, 1996). Além disso, em processo industriais, os defeitos em produtos inspecionados costumam ser detectados de modo mais claro através do arranjo textural de sua superfície (SILVA; ROESE; KINDLEIN, 2009). Estas aplicações dependem fortemente da informação visual extraída de imagens que são utilizadas para descrevê-las eficientemente.

As texturas podem ser interpretadas como um conjunto de determinados padrões em formato repetitivo ou não, que ocorrem na natureza. Esses padrões são observados diariamente com frequência (Figura 2.1). Como exemplo de padrão repetitivo, tem-se uma simples parede de tijolos com o posicionamento de cada tijolo sobreposto um ao outro, juntamente com suas camadas de cimentos. Um exemplo de padrão não repetitivo, tem-se estruturas geológicas, como as mostradas por Haralick, Shanmugam e Dinstein (1973), onde são capturadas imagens de texturas de reservatórios rochosos, ou seja, texturas completamente diferentes uma das outras.



(a) Tijolos



(b) Imagem de Satélite da Califórnia Central. Fonte (HARALICK; SHANMUGAM; DINSTEIN, 1973)

Figura 2.1: Exemplos de texturas com padrões repetitivos e não repetitivos.

De um modo geral, uma textura é caracterizada pelas informações sobre a distribuição espacial e a variação de luminosidade contidas em um objeto ou imagem, e também descreve o arranjo estrutural das superfícies e relações entre regiões vizinhas, que na maioria das vezes são constituídas por padrões repetitivos, cuja disposição pode ser periódica ou aleatória (PEDRINI H.; SCHWARTZ, 2008). Normalmente, texturas naturais são aleatórias, enquanto que texturas artificiais são frequentemente determinísticas ou periódicas (PAGAMISSE; DUTRA, 2004). Ademais, termos como fina, áspera, grossa, suave, alongada, granulada, regular e irregular estão também associados a texturas (PAGAMISSE; DUTRA, 2004). Tudo isso a torna um excelente descritor regional capaz de contribuir na melhoria da exatidão do processo de reconhecimento, descrição e classificação de imagens (CHOI et al., 2002).

Este capítulo apresenta uma revisão acerca das características de textura e das abordagens utilizadas para sua análise. Assim, é feita uma revisão das definições de textura e de suas diversas aplicações.

## 2.2 Textura

As texturas estão presentes em praticamente toda a matéria. Pode-se encontrá-las na natureza e nos objetos ao redor. Elas estão em paredes, tecidos, pisos, rochas, árvores, na pele humana e dos animais, etc. São as características texturais que normalmente diferenciam um objeto natural de um objeto artificial. Para os seres humanos, a textura refere-se ao tato: diferenças nas superfícies ásperas ou lisas. Texturas em imagens digitais são as diferenças locais nos níveis de intensidade: diferenças em níveis de cinza (contraste); tamanho de área onde essas diferenças ocorrem e direcionalidade (HARALICK; SHANMUGAM; DINSTEN, 1973).

Apesar de que, a percepção de textura seja intuitiva (pois é possível reconhecê-la somente por observá-la), ainda não existe uma definição precisa. Neste sentido, a literatura tem apresentado diferentes definições para textura.

“Uma textura é compreendida como uma primitiva que é repetida sobre uma região que é maior em comparação ao tamanho da primitiva” (COGGINS, 1982).

“Textura pode ser descrita por propriedades espaciais, propriedades de frequência ou propriedades perceptuais” (BIMBO, 1999).“

“Textura é um arranjo repetitivo de padrões sobre uma área e tentam medir sua

aspereza, observando fatores como a dependência de níveis de cinza e autocorrelação” (ROSENFELD; TROY, 1970).

Zucker e Kant (1981) reconheceram “a textura como um conceito paradoxal, no qual seu uso é comum em pré-processamento da informação visual, especialmente para propósitos de classificação”.

Para Sklansky (1978), uma região em uma imagem apresenta uma textura única se um conjunto de características estatísticas ou outras propriedades locais da imagem forem constantes, com pouca variação ou aproximadamente periódicas.

Entre outras definições presentes na literatura, destaca-se as de:

Haralick (1979):

uma imagem de textura é descrita pelo número e tipos de suas primitivas (tonais), e a organização espacial ou distribuição de suas primitivas (tonais), que ocorrem em diferentes números e formas. Pixels contíguos que apresentam propriedades semelhantes formam cada uma das primitivas, dentre as quais podem ocorrer interações aleatórias ou com certo grau de dependência. Uma característica fundamental da textura é que não pode ser analisada sem um quadro de referência da primitiva tonal, seja explícita ou implícita.

Tamura, Mori e Yamawaki (1978):

a textura é considerada como aquilo que constitui uma região macroscópica. Sua estrutura é simplesmente atribuída aos padrões repetitivos nos quais elementos ou primitivas estão organizados de acordo com uma regra de colocação ou composição. Também propuseram que imagens de textura poderiam ser avaliadas com base em propriedades como coeficiente de uniformidade, densidade, aspereza, regularidade, intensidade, dentre outras características. Nesse mesmo trabalho, os autores caracterizam textura como um conceito bidimensional, onde uma dimensão contém as propriedades primitivas da tonalidade e a outra corresponde aos relacionamentos espaciais entre elas. Eles indicaram que os conceitos de tonalidade e textura não são independentes, tal que em algumas imagens a tonalidade é dominante e, em outras, a textura é dominante.

Hawkins (1970):


a noção de textura parece depender de três ingredientes: (i) alguma ‘ordem’ local é repetida sobre uma região, que é grande em relação ao tamanho da ordem; (ii) a ordem consiste em um arranjo não aleatório de partes elementares; e (iii) as partes são geralmente entidades uniformes que possuem aproximadamente as mesmas dimensões em toda parte dentro da região de textura.

Haralick, Shanmugam e Dinstein (1973):


textura é uma propriedade inata a virtualmente todas as superfícies. Ela contém informações relevantes sobre o arranjo estrutural das superfícies e sua relação com o ambiente ao redor. A definição de textura está relacionada com o uso de coeficientes de uniformidade, densidade, aspereza, regularidade, intensidade, dentre outras características de uma imagem.

Este conjunto de definições demonstra que a definição de textura é formulada por pesquisadores diferentes e não há um consenso geral.


A repetição de certos padrões em uma imagem permite uma série de características visuais, que podem ser identificadas como por exemplo, direcionais, ásperas, finas, suaves e uniformes (WU, 2003; TAMURA; MORI; YAMAWAKI, 1978). Alguns exemplos desse tipo de características visuais podem ser observados na Figura 2.2: (a) - (d). Note-se que cada textura pode estar associada a uma ou mais destas características.




(a) Direcionais vs. não-direcionais



(b) Suaves vs. não-suaves



(c) Finas vs. ásperas



(d) Uniformes vs. não-uniformes

Figura 2.2: Alguns tipos de características visuais de textura. Fonte (BRODATZ, 1966)

### 2.2.1 Tipos de Classificação das Texturas

As texturas podem ser descritas e classificadas de acordo com algumas propriedades.

- Pratt (1991) classifica às texturas em dois tipos:
  - artificiais: são aquelas que consistem em arranjos de símbolos, tais como segmentos de linhas, pontos, estrelas, etc., dispostos sobre um fundo neutro (HARALICK; SHANMUGAM; DINSTEIN, 1973). Nas texturas artificiais observam-se certos padrões repetitivos, como podem ser encontrados na Figura 2.3;





Figura 2.3: Exemplos de texturas artificiais. Fonte (PRATT, 1991)

- naturais: são compostas por cenários encontrados na natureza, contendo arranjos do tipo semi-repetitivos. Na Figura 2.4 pode-se observar alguns tipos de texturas naturais.



(a) Areia

(b) Grama

(c) Lã

Figura 2.4: Exemplos de texturas naturais. Fonte (PRATT, 1991)

- Haralick (1979) classifica as texturas como fortes ou fracas, sendo mais fortes quanto maior a sua regularidade, ou seja, a interdependência das primitivas de textura.
- Castleman (1996) afirma que as texturas são quantificadas avaliando-se aspectos relativos à variação de tons de cinza em seções contidas na imagem.

## 2.3 Aplicações da textura

A falta de uma definição clara e precisa, do que é textura, torna o problema da análise de textura mais difícil desde o ponto de vista matemático, pois os diferentes métodos não podem ser verificados como certos ou errados, fazendo com que sua avaliação seja conduzida de maneira empírica; neste caso, a análise tende a ser orientada pela aplicação desejada. As definições dos conceitos de textura encontradas na literatura, estão associadas a sua aplicação em diversas áreas. Cada uma delas encontra-se brevemente discutida a seguir.

### 2.3.1 Classificação de textura

A classificação de textura baseia-se principalmente na seguinte ideia: dada uma imagem *desconhecida* é possível determinar a qual classe de texturas *conhecidas* pertence, por meio de suas propriedades texturais. Em geral, a classificação de textura envolve duas fases, a fase de **treinamento** e a fase de **reconhecimento**.

Na fase de treinamento, é criado um modelo de representação para cada classe de texturas presentes nos dados de treinamento, em geral o treinamento é realizado através de rótulos de classes conhecidas. Para criar esse modelo, utiliza-se um método que procura caracterizar as propriedades mais significativas da textura, depois extrai-se um conjunto de vetores de características para cada uma das imagens. Em geral, esses vetores de características consistem em números reais, os quais representam algumas propriedades das texturas tais como orientação, luminosidade, contraste, etc (HARALICK; SHANMUGAM; DINSTEIN, 1973).

Na fase de reconhecimento, emprega-se o mesmo método utilizado na etapa de treinamento, para extrair o vetor de características da imagem a ser classificada (desconhecida). Seguidamente, compara-se o vetor de características extraído com aqueles obtidos das imagens do conjunto de treinamento, por meio de um algoritmo de classificação. Desse modo, as características de texturas das amostras são comparadas com aquelas de treinamento

e a amostra é atribuída àquela categoria que apresenta maior similaridade.

Existem dois procedimentos para a classificação de texturas: a classificação *supervisionada* e a classificação *não-supervisionada* (SILVA; LIMA; DANTAS, 2006). A classificação *supervisionada* consiste em dispor de informações *a priori* de regiões da imagem, as quais permitem a identificação de uma classe de interesse. A classificação é dita *não-supervisionada*, quando não utiliza nenhuma informação sobre as classes existentes na imagem. O padrão associado a uma classe é aprendido com base na similaridade entre os padrões de treinamento, ou seja, são utilizados algoritmos para reconhecer as classes presentes na imagem (BINS; ERTHAL; FONSECA, 1993). Neste caso, o algoritmo baseia-se na análise de agrupamentos (*clustering*), onde cada grupo (*cluster*) representa a distribuição de probabilidade de uma classe.

Para um treinamento supervisionado, deve-se identificar na imagem uma área representativa de cada classe. A área de treinamento deve ser uma amostra homogênea, mas ao mesmo tempo, deve incluir toda a variabilidade dos níveis de cinza (PEDRINI H.; SCHWARTZ, 2008). Enquanto que para o treinamento não-supervisionado, as áreas escolhidas devem ser heterogêneas para proporcionar que todas as possíveis classes sejam incluídas.

Muitas vezes pode preferir os dois tipos de classificação, um após o outro (classificação híbrida), ou seja, inicialmente o não supervisionado, para confirmação das classes, e depois o da classificação supervisionada (SILVA; LIMA; DANTAS, 2006).

### 2.3.1.1 Classificadores

1. **Distância Mínima:** Este classificador é muito eficiente devido à simplicidade de seu algoritmo. Na fase de treinamento determina-se os protótipos para cada uma das classes, no mínimo um. Os protótipos são vetores criados a partir de informações obtidas do conjunto de treinamento. Um protótipo muito comum, por exemplo, é a média do conjunto de treinamento das classes (NASCIMENTO, 2003). Após isso, na fase de classificação, cada padrão é atribuído à classe do protótipo mais perto.

Existem diversas distancias que podem ser utilizadas para calcular a proximidade entre os padrões e os protótipos.

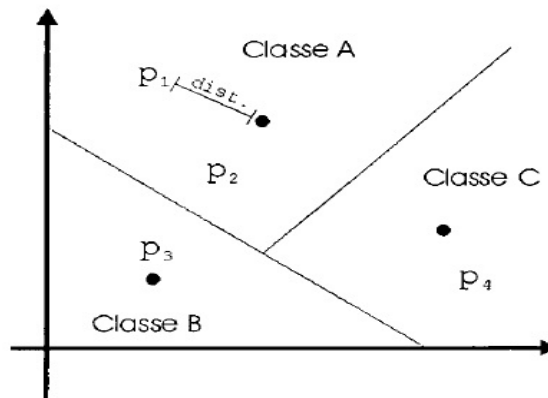


Figura 2.5: Classificador Distância Mínima. Fonte (NASCIMENTO, 2003)

Observa-se na Figura 2.5, quatro pixels  $p_1$ ,  $p_2$ ,  $p_3$  e  $p_4$  dentro de três classes (Classe A, Classe B e Classe C), os pontos pretos representam o centro de cada classe (os protótipos para cada classe). Cada pixel é classificado pela menor distância entre o pixel e o centro de cada classe. Portanto,  $p_1$  e  $p_2$  pertencem à Classe A,  $p_3$  pertence à Classe B e  $p_4$  pertence à Classe C (NASCIMENTO, 2003).

2. **Support Vector Machine:** ou Máquina de Vetor de Suporte (SVM do Inglês *Support Vector Machine*) foi desenvolvido por Vapnik (1995), baseado na ideia da Minimização do Risco Estrutural (*Structural Risk Minimization* - SRM) (ABE, 2005). As SVM's tem por objetivo separar as classes de um problema da melhor forma possível, ou seja, encontrar o hiperplano (Figura 2.6) que os separa e maximizar a margem de separação entre as classes (LORENA; CARVALHO, 2007).

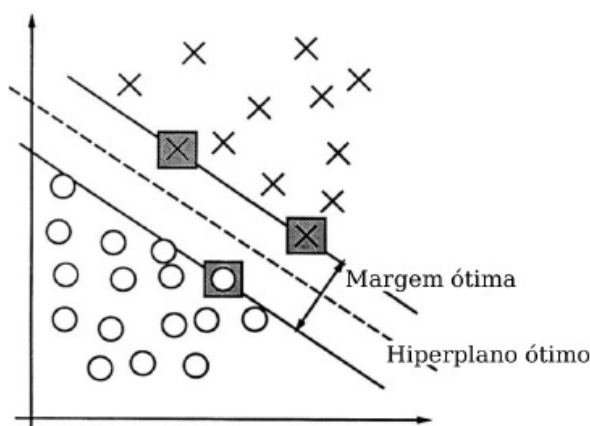


Figura 2.6: Separação de dados em um espaço bidimensional. Fonte (CORTES; VAPNIK, 1995)

3.  **$K$ -vizinhos mais Próximos:** ( $K$ -NN do inglês *K-Nearest Neighbor*) é uma variação do algoritmo NN (*Nearest Neighbor*), o qual faz uso dos  $K$ -vizinhos mais próximos, ao invés de utilizar apenas o vizinho mais próximo. “O  $K$ -NN é um método simples de estimação de densidade” (WEBB, 2005), devido ao fato de estimar a densidade dos padrões de treinamento numa vizinhança do padrão desconhecido. Dado um padrão  $X$  (desconhecido), o  $K$ -NN calcula a distância entre  $X$  e seus  $K$ -vizinhos mais próximos, depois  $X$  é atribuído à classe que apresenta maior frequência dentre os seus  $K$ -vizinhos.




Figura 2.7: Classificador  $K$ -vizinhos mais próximos. Fonte (MARTINS et al., 2005)

Na Figura 2.7, observa-se o classificador  $K$ -NN num espaço bidimensional, onde existem 3 classes com suas amostras e dois elementos desconhecidos ( $X$  e  $Y$ ). Pretende-se classificar esses dois elementos utilizando 7 vizinhos mais próximos ( $K = 7$ ) para cada ponto desconhecido, os quais são apresentados pelas linhas que os conectam. O elemento desconhecido  $X$  pertence à classe  $B$  devido ao fato de que o elemento  $X$  ter maior número de amostras da classe  $B$ , enquanto que o elemento desconhecido  $Y$  pertence à classe  $A$  (MARTINS et al., 2005).

### 2.3.1.2 Métricas para avaliar os classificadores

Para avaliar os resultados de um classificador, utiliza-se a matriz de confusão (também chamada de tabela de contingência), a qual mostra as predições corretas, bem como das confusões geradas.

Na matriz de confusão  $k \times k$ , os elementos da diagonal principal (*linha = coluna*) dão o número dos acertos do classificador. Os elementos das colunas  $i$  da matriz con-

tém o número das amostras que o classificador identificou como sendo das classes 1 a  $k$  (MATHER, 2004). Na Tabela 2.1 observa-se uma matriz de confusão de duas classes.

		Classe Predita	
		P	N
Classe correta	P	Verdadeiro Positivo (VP)	Falso Negativo (FN)
	N	Falso Positivo (FP)	Verdadeiro Negativo (VN)

Tabela 2.1: Matriz de confusão de duas classes. Fonte (BAGESTEIRO, 2015)

A partir desta matriz, quatro indicadores são extraídos: VP-número de amostras verdadeiras classificadas corretamente, FP-número de amostras falsas classificadas como positivas, FN-número de amostras verdadeiras classificadas como negativas e VN-número de amostras falsas classificadas como negativas. Em seguida, são calculadas as métricas (BAGESTEIRO, 2015):

- Sensibilidade ( $S$ ): proporção de amostras positivas que foram corretamente identificadas como positivas.

$$S = \frac{VP}{VP + FN}. \quad (2.1)$$

- Especificidade: proporção de amostras negativas que foram corretamente identificadas como negativas

$$\text{Especificidade} = \frac{VN}{VN + FP}. \quad (2.2)$$

- Precisão: calcula a precisão das predições de uma classe.

$$\text{Precisão} = \frac{VP}{VP + FP}. \quad (2.3)$$

- Acurácia ( $Acc$ ): calcula a proporção de resultados verdadeiros (VP e VN) entre o total de classes.

$$Acc = \frac{VP + VN}{VP + FP + VN + FN}. \quad (2.4)$$

A Tabela 2.2 exibe a matriz de confusão gerada por um classificador, de 200 amostras e 5 classes. Na diagonal principal, tem-se as amostras que foram classificadas corretamente e nas demais células os erros da classificação. Por exemplo, para a **Classe 1**, 2 delas são classificadas como pertencentes à Classe 2 e 2 são classificadas como pertencentes à Classe 4. Para a **Classe 2**, 1 é classificada como pertencentes à Classe 1 e 2 são classificadas como pertencentes à Classe 4.

	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5
Classe 1	196	1	1	0	0
Classe 2	2	197	0	0	0
Classe 3	0	0	194	1	0
Classe 4	2	2	5	199	2
Classe 5	0	0	0	0	198

Tabela 2.2: Matriz de confusão de cinco classes

### 2.3.2 Segmentação de textura

A segmentação de textura consiste em decompor uma dada imagem em regiões de diferentes texturas.

Quando existe alguma informação a priori dos tipos de textura presentes numa imagem, a segmentação será dita *supervisionada*. A segmentação será dita *não supervisionada* caso as regiões tenham que ser agrupados com base em medidas de similaridade,. Além disso, os métodos de segmentação podem ser classificados como sendo baseados em regiões ou contornos. Na figura 2.8 são apresentados alguns exemplos de imagens segmentadas.



Figura 2.8: Exemplos de alguns métodos de segmentação de texturas: (a) Fonte (DENG; MANJUNATH, 2001), (b) Fonte (ALLILI; ZIOU, 2007)

A tarefa de segmentação baseia-se principalmente em dois fases, a identificação das

texturas presentes na imagem e a determinação das fronteiras dessas regiões. Esta ideia consiste em determinar as fronteiras adjacentes de regiões texturais diferentes para que possam ser identificadas.

### 2.3.3 Percepção de Forma a partir de textura

Como foi dito anteriormente, a textura também é um termo intuitivo associado à percepção humana de diferentes objetos encontrados na natureza. Experimentos psicológicos demonstraram que a textura é muito importante na percepção de formas. Neste sentido, as técnicas de obtenção de forma a partir de textura consiste em obter a orientação da superfície ou seu formato (forma 3D) a partir de um objeto textural contido numa imagem (BLAKE; MARINOS, 1990).

### 2.3.4 Síntese de Textura

A síntese de textura baseada em amostras utiliza uma pequena textura como fonte para gerar uma textura que tem aparência bastante semelhante em relação à amostra inicial (WEI; LEVOY, 2000). Em outras palavras, dada uma pequena amostra de textura, sintetiza-se em uma nova textura, tal que quando seja observado por um ser humano, esta aparente ter sido gerada pelo mesmo processo.

Os algoritmos de síntese de textura, oferecem algumas vantagens, como, por exemplo, definir as dimensões da nova textura. Ao longo dos anos, surgiram varias técnicas de síntese de texturas, inicialmente baseadas em pontos, ate as técnicas baseadas em *patches* (ou blocos que são parte da amostra selecionada para gerar alguns pixels na imagem de saída) (MAGDA; KRIEGMAN, 2003). Os métodos baseados em pontos procuram sintetizar as texturas colorindo um pixel a cada vez. Quando o método baseá-se em *patches*, a textura final é formada pela junção de dois pedaços ou blocos da amostra original (WEI; LEVOY, 2000).

Na Figura 2.9 são apresentados alguns exemplos de síntese de imagens.




Figura 2.9: Alguns exemplos de síntese de texturas. Fonte (WEI; LEVOY, 2000)

### 2.3.5 Recuperação de imagens por conteúdo

Devido ao aumento de informações visuais nas mais diversas áreas, tais como medicina, desenho de moda, entretenimento, etc, hoje em dia, um tema de grande interesse é a probabilidade da recuperação de imagens por similaridade do seus conteúdos (CBIR- do inglês *Content-Based Image Retrieval*).

Os sistemas CBIR tem por objetivo procurar imagens similares à uma imagem consulta ou modelo dentre de um banco de dados de imagens, utilizando suas características do interesse para o usuário. As imagens armazenadas e a imagem consultada devem estar representadas por suas características visuais (cor, textura, forma, etc) para que possam ser comparadas umas com as outras (RUI; HUANG; CHANG, 1999).

As etapas para recuperação de imagens por conteúdo encontra-se brevemente detalhados a seguir (SMEULDERS et al., 2000):

- extração de características visuais das imagens utilizando técnicas de Visão Computacional;
- as imagens são representadas por um vetor de características, o qual contem as características extraídas;
- calcular a similaridade entre os vetores de características extraídos da imagem base e das imagens armazenadas no banco de dados, classificando-as de maneira que as imagens do topo da lista de classificação (*ranking*) sejam as mais semelhantes em relação à imagem base.

Em alguns sistemas de CBIR adiciona-se ainda o processo de realimentação de relevância (*relevance feedback*), que consiste num processo de refinamento da consulta, gerando-se assim resultados mais significativos do ponto de vista visual. Na Figura 2.10 é apresentado um diagrama típico de recuperação de imagens por conteúdo CBIR.

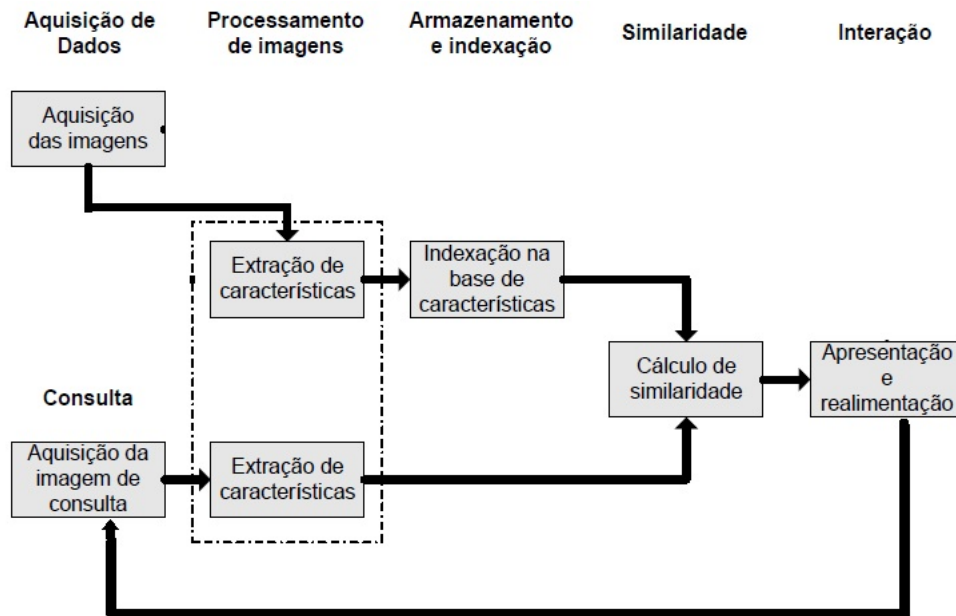


Figura 2.10: Diagrama típico de sistemas CBIR. Fonte (SMEULDERS et al., 2000)

Uma importante característica dos sistemas de recuperação de imagens por conteúdo é que ao invés de se obter uma única imagem, um conjunto de  $N$  imagens pode ser encontrado (LEMOS; REIS; OLIVEIRA, 2000). Nesse caso, cada uma das imagens é

ordenada em relação à sua similaridade com a imagem de consulta. Note que a definição da quantidade de imagens a ser recuperada  $N$ , é dado pelos requisitos do sistema.

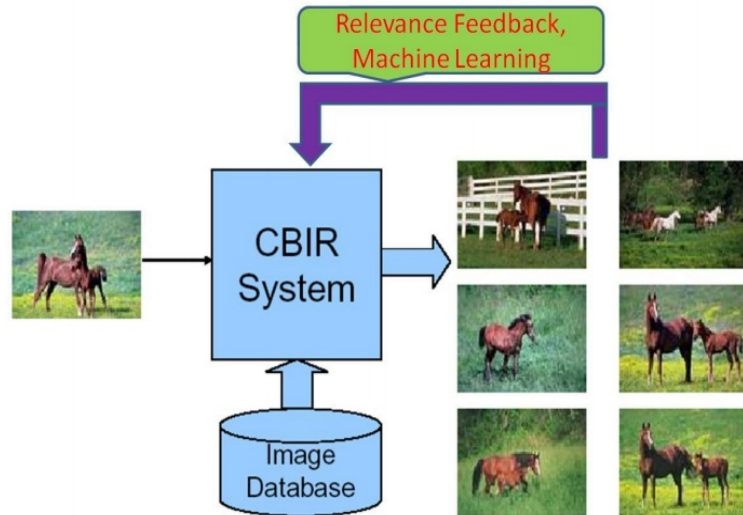


Figura 2.11: Exemplo de um sistema CBIR. Fonte (LEMOS; REIS; OLIVEIRA, 2000)

Alguns exemplos deste tipo de sistemas na literatura incluem: Photobook (PENTLAND; PICARD; SCLAROFF, 1994), VisualSEEk (SMITH; CHANG, 1996) e Cortina (GELASCA et al., 2007).

## 2.4 Abordagens para descrição de textura

Devido à subjetividade inerente de textura, nos últimos anos vários descritores foram desenvolvidos, cada um deles seguindo uma abordagem conforme a definição de textura assumida.

Gonzalez e Woods (2002) propõem três abordagens principais para a descrição de textura: estatísticas, estruturais e espectrais. Esta categorização não é única, devido ao fato de que diferentes autores fazem outra categorização, como por exemplo, Nixon e Aguado (2008) consideram as abordagens estatística, espectral e abordagem combinatória. Xie (2008) categoriza os métodos em estatística, estrutural, baseada em filtros e baseada em modelos.

Nas próximas seções são apresentados os principais abordagens utilizadas para descrição de texturas.

### 2.4.1 Abordagem estatística

Nos métodos estatísticos, a textura é descrita por uma coleção de estatísticas sobre a distribuição e relação entre os níveis de cinza de uma imagem. Nesse tipo de abordagem, um vetor de características é utilizado para representar a textura (CHIERICI, 2015). O objetivo é encontrar uma regra de decisão probabilística associando a textura à alguma classe específica (SONKA; HLAVAC; BOYLE, 2008). As abordagens estatísticas tentam representar a textura indiretamente, por meio de propriedades não determinísticas das distribuições e relacionamentos entre os níveis de cinza de uma imagem.

Zhang e Tan (2002) afirmam que o sistema de visão humano utiliza recursos estatísticos para discriminação de textura dependendo do número de pixels que definem as características locais. Esses métodos podem ser classificados como estatística de primeira ordem (um pixel), segunda ordem (dois pixels) e alta ordem (três ou mais pixels) (OJALA; PIETIKÄINEN, 2013). A diferença básica é que a estatística de primeira ordem estima propriedades (média, variância, desvio padrão, assimetria, curtose e etc.) de pixels individuais, ignorando as interações entre os pixels, enquanto que nas estatísticas de segunda e alta ordem analisa-se o posicionamento espacial de cada pixel em relação a sua vizinhança.

Uma das abordagens utilizadas para adquirir informações sobre transições de níveis de cinza entre dois pixels, proposto por Haralick, Shanmugam e Dinstein (1973), é obtida através da construção da *matriz de co-ocorrência*, baseada na ocorrência repetida de níveis de cinza entre dois pixels vizinhos, um chamado de pixel referência e outro de pixel vizinho, separados espacialmente por um vetor de distância fixo. Efetuando variações na relação espacial, podem ser obtidas diversas matrizes de co-ocorrência, a partir das quais são extraídas medidas utilizadas para a análise de texturas. Essa matriz é utilizada para diversos cálculos estatísticos, como no caso da extração de características de Haralick, Shanmugam e Dinstein (1973) que definiram 14 medidas texturais: variância, segundo momento angular, energia, contraste, correlação, homogeneidade, momento inverso da diferença, soma da média, soma da variância, soma da entropia, diferença da variância, diferença da entropia, medida de informação da correlação e coeficientes de correlação máxima.

Embora seja amplamente utilizada em análise de texturas, a matriz de co-ocorrência apresenta alguns problemas, tais como a inexistência de um método para a seleção da distância entre os pixels, e a não captura dos aspectos das primitivas contidas na textura. Para isso Haralick (1979) ainda apontou oito abordagens estatísticas para a medição e caracterização de textura: funções de autocorrelação, transformadas ópticas, transformadas

digitais, bordas texturais, elementos estruturantes, probabilidades de co-ocorrência espacial de níveis de cinza, comprimento de corrida de nível de cinza (*run length*) e modelos auto regressivos.

### 2.4.2 Abordagem estrutural (ou geométrica)

Este tipo de abordagem introduz o conceito de *texel* ou *texton*, um termo que representa uma unidade primitiva de discriminação de textura (JULESZ, 1981). Nessa abordagem, a estrutura espacial de uma textura é enfatizada, sendo descrita a partir de um vocabulário de “textons” e de uma descrição da relação entre estes elementos, que pode ser expresso em termos de adjacência, distância mais próxima ou periodicidade. Na abordagem geométrica, uma textura é definida como sendo composta por primitivas. Após a identificação das primitivas que a compõem, duas classes de métodos são utilizadas para a extração de características. A primeira utiliza medidas extraídas das primitivas para descrever a textura, enquanto a segunda extrai regras para descrever a disposição espacial e o relacionamento existente entre as primitivas (CHIERICI, 2015).

Algumas texturas podem ser interpretadas como padrões bidimensionais constituídos por um conjunto de primitivas ou subpadrões, que são dispostos de acordo com certas regras de posicionamento para sua geração (VIERA, 2013). Os principais objetivos das abordagens estruturais são extrair primitivas da textura e modelar ou generalizar as regras de posicionamento espacial. A textura primitiva pode ser tão simples como pixels individuais ou uma região com níveis de cinza uniforme.

As abordagens estruturais são consideradas apropriadas quando a primitiva de textura é grande o suficiente para ser individualmente segmentada e descrita. A primitiva de textura é a estrutura geométrica básica que forma a textura. Em texturas muito finas de imagens digitais, pode ser o próprio pixel (VIERA, 2013). A vantagem da abordagem estrutural é que ela provê uma boa descrição simbólica da imagem. Entretanto, essa característica é mais útil em tarefas de síntese do que em análise de textura. Outra dificuldade desta abordagem ocorre devido à dificuldade de identificar tais primitivas e encontrar padrões regulares que possibilitem sua utilização.

### 2.4.3 Abordagem espectral

A abordagem espectral é baseada nas propriedades de espectros de frequência, comumente obtidos pela aplicação de transformadas, como a de Fourier, Gabor e Wavelets.

Na abordagem espectral baseada no espectro de Fourier, detecta-se a existência de padrões periódicos ou semi-periódicos. Na transformada de Fourier, imagens de domínio espacial são transformadas para o domínio da frequência, decompondo uma imagem em suas componentes seno e cosseno.

Gabor (1946) desenvolveu uma técnica que consiste em uma variante local da transformada de Fourier bastante eficiente no processo de análise de textura a partir de frequências espaciais. Devido a sua capacidade de caracterizar um sinal simultaneamente nos domínios temporal e da frequência, que são limitados pela relação de incerteza conjunta.

A transformada *Wavelet* permite a variação da resolução espacial, habilitando a representação de texturas numa escala mais adequada. A transformada *Wavelet* converte um sinal dentro de séries de *wavelets*, que podem ser armazenadas mais eficientemente devido ao tempo finito (WOUMER; SCHEUDERS; DYCK, 1999).

## 2.5 Considerações Finais

Neste capítulo inicialmente foram introduzidos os diferentes conceitos de textura presentes na literatura, sendo que cada conceito depende de sua aplicação em áreas distintas. Além disso, foram apresentadas as principais abordagens (estatístico, espectral e estrutural) para a análise de texturas, cujas aplicações variam desde síntese, classificação, segmentação até recuperação de imagens por conteúdo.

No próximo capítulo encontram-se descritos os padrões responsáveis para se obter uma boa precisão na classificação das amostras de texturas.

## CAPÍTULO 3

# DESCRITORES DE TEXTURA

Neste capítulo aborda-se os principais descritores de textura, os quais modelam algoritmos que tenham a capacidade de analisar as propriedades da superfície de um objeto. Os descritores de textura local realizam esta atividade analisando uma vizinhança e codificando cada uma delas, gerando, desse modo, as relações das intensidades relativas entre os pixels em uma vizinhança e não sobre os valores de intensidade absolutos.

### 3.1 Texture Unit (TU)

O *Texture Unit* foi apresentado por He e Wang (1990), é uma técnica que relaciona os níveis de cinza de uma vizinhança para a classificação de micropadrões de textura.

Neste modelo a informação de textura é coletada de uma janela de pixels (vizinhança)  $3 \times 3$  retirada de uma imagem, que representa a menor unidade da imagem, no sentido de ter oito direções em torno dos pixels. Na Figura 3.1, observa-se uma vizinhança  $V = \{V_0, V_1, V_2, \dots, V_8\}$  onde  $V_0$  representa o valor do pixel central em escala de cinza e  $V_i$  ( $i \neq 0$ ) os valores em escala de cinza dos vizinhos localizados nas oito direções. O *Texture Unit* é definido como o conjunto  $TU = \{E_1, E_2, \dots, E_8\}$ , onde  $E_i$  é obtido comparando-se os  $V_i$  com o pixel central  $V_0$ .




Figura 3.1: Conversão da vizinhança em *Texture Unit*

Cada pixel da vizinhança ( $V_i$ ) assume o valor ( $E_i$ ) 0, 1 ou 2, dependendo se o pixel central seja maior que o pixel vizinho, se o pixel central e o seu vizinho possuam valores iguais e , se o pixel central seja menor que o pixel vizinho, respectivamente, como mostra a Equação 3.1

$$E_i = \begin{cases} 0, & \text{se } V_i < V_0 \\ 1, & \text{se } V_i = V_0 \\ 2, & \text{se } V_i > V_0 \end{cases} \quad (3.1)$$

Uma unidade de textura para uma vizinhança é produzida multiplicando-se os valores limiarizados pelos pesos dados aos pixels correspondentes e, posteriormente, somando-se o resultado, obtendo-se assim, o código TU da Equação 3.2 que caracteriza um determinado micropadrão da imagem.

$$N_{TU} = \sum_{i=1}^8 E_i \cdot 3^{i-1}. \quad (3.2)$$

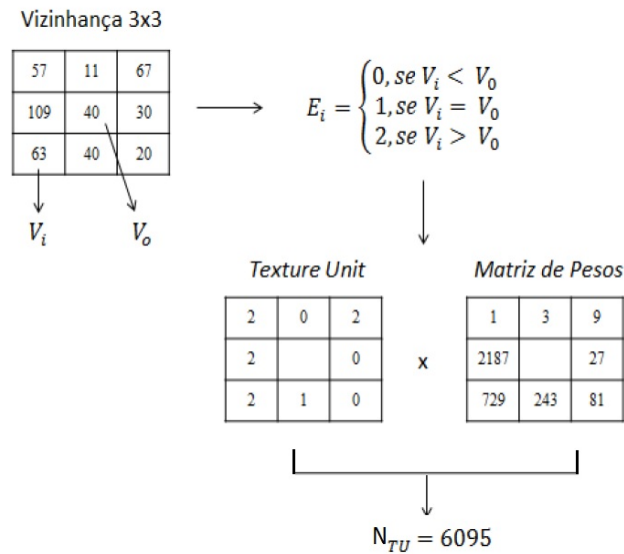


Figura 3.2: Cálculo do *Texture Unit*. Fonte (TRAVAINI, 2015)

A descrição global da imagem é obtida a partir do histograma destas unidades de texturas chamado de *Texture Spectrum* (TS). A Figura 3.2 mostra a geração do *Texture Unit*. Infelizmente, este descritor não é muito efetivo, pois o método gera grande quantidade de códigos:  $3^8 = 6561$  possibilidades diferentes. A abordagem TS foi aplicada na caracterização, como filtro, na classificação e na detecção de bordas em imagens de textura (HE; WANG, 1990).

## 3.2 Local Binary Pattern (LBP)

Tomando por base a metodologia *Texture Unit*, Ojala, Pietikäinen e Harwood (1996) propuseram um novo método, chamado de padrões locais binários (*Local Binary Pattern* LBP), um poderoso descritor de texturas. O LBP busca realizar a comparação do pixel central com seus oito vizinhos para adquirir um código que caracterize a micro região selecionada.

Nesse método uma vizinhança  $3 \times 3$  é limiarizada pelo valor do pixel central gerando uma matriz com valores binários resultante da comparação: valor binário 1 nos vizinhos que tem valor superior ou igual ao pixel central e 0, caso contrário. A limiarização do descritor  $LBP = \{E_1, E_2, \dots, E_8\}$  é obtido por:

$$E_i = \begin{cases} 0, & \text{se } V_i < V_0 \\ 1, & \text{se } V_i \geq V_0 \end{cases}. \quad (3.3)$$

Os valores dos pixels na vizinhança limiarizada são multiplicados pelos pesos dados aos pixels correspondentes. Concluída esta etapa, realiza-se a soma destes valores, resultando no valor do código LBP (Equação 3.4).

$$N_{LBP} = \sum_{i=1}^8 E_i \cdot 2^{i-1}. \quad (3.4)$$

Em seguida, um histograma é criado para computar as ocorrências dos diferentes códigos LBP de todos os pixels da imagem. Esse histograma forma o vetor de características LBP, que caracteriza a imagem de textura. A maior diferença entre o TU e o LBP é o fato de o segundo possuir apenas  $2^8 = 256$  códigos resultantes.

Apesar de seu poder para descrição de texturas, o método original apresenta o inconveniente de não ser robusto a variações de rotação, devido ao uso da matriz de pesos baseada em potência de dois (PIETIKÄINEN; OJALA; XU, 2000). Este problema foi resolvido depois por Ojala, Pietikäinen e Mäenpää (2002) quando introduziram duas variações ao método LBP original: o LBP *ri* (*rotation invariant*) e o LBP *riu* (*rotation invariant uniform*).

O LBP *ri* e o LBP *riu* são muito similares ao LBP original. Esses métodos estenderam a definição do LBP para vizinhanças circulares mais abrangentes, adequado para a análise multi-escalar (por apresentarem mais de uma etapa (escala) na extração da informação requerida). A vizinhança do pixel central é indexado circularmente e depois os pixels da vizinhança em posição diagonal são obtidos por interpolação. Portanto o número de vizinhos  $P$  quanto o valor do raio da vizinhança  $R$  podem ser definidos conforme o problema a que se destinam. A Figura 3.3 apresenta a vizinhança de um pixel para distintos valores de  $P$  e  $R$ .




Figura 3.3: Conjuntos de vizinhanças circulares simétricas (MÄENPÄÄ; PIETIKÄINEN, 2003).

Deste modo, define-se o descritor através da Equação 3.5:

$$LBP_{P,R} = \sum_{k=0}^{P-1} s(g_k - g_c) 2^k, \quad (3.5)$$

em que  $P$  é o número de amostras (pixels  $g_0, g_1, \dots, g_{P-1}$ ) igualmente espaçadas a uma distância  $R$  do pixel central  $g_c$  e presentes em sua vizinhança, e  $s$  é dada pela Equação 3.6:

$$s(x) = \begin{cases} 1, & \text{se } x \geq 0 \\ 0, & \text{se } x < 0 \end{cases}. \quad (3.6)$$

Pela Equação 3.4 o descritor LBP gera valores inteiros contidos na faixa  $[0, 255]$ .

A Figura 3.4 exemplifica a geração do código LBP, que é a forma simplificada de denotar o valor  $LBP_{8,1}$  dado na Equação 3.5, em uma vizinhança  $3 \times 3$  de um pixel.

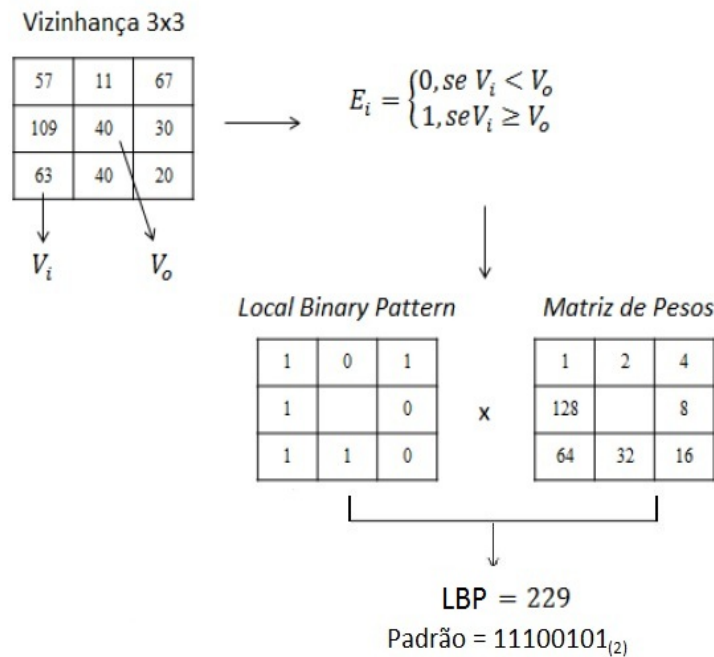


Figura 3.4: Cálculo do *Local Binary Pattern*. Fonte (TRAVAINI, 2015)

O código LBP invariante à rotação (LBP *ri*) é conseguido através da rotação circular do código original (LBP) até atingir o valor mínimo, definido pela Equação 3.7:

$$LBP_{P,R}^{ri} = \min\{ROR(LBP_{P,R}, i) | i = 0, 1, \dots, P - 1\} \quad (3.7)$$

na qual  $ROR(x, i)$  executa  $i$  vezes a operação de *bit shifting* circular à direita no número binário  $x$ .

Mäenpää et al. (2000) apresentaram o conceito de uniformidade da sequência binária obtida ao calcular o LBP, tendo em conta que certos padrões locais binários denominados “**uniformes**” representam mais de 90% de todos os padrões locais da imagem. Para medir a uniformidade da sequência, basta calcular o número de transições entre zeros e uns presentes. Se o número de transições for menor ou igual a 2, o padrão é considerado uniforme *uniform patterns*.

Jia et al. (2014) assegura que, para  $P$  amostras, existem  $(P - 1).P + 2$  padrões uniformes. Quando  $P = 8$ , existem 58 valores entre  $[0, 255]$  *uniform patterns*.

Além dos 58 padrões uniformes, Ojala, Pietikäinen e Mäenpää (2002), afirmam que os demais padrões não uniformes devem ser armazenados em uma coluna adicional do histograma, no total 59 características. Essa variação do LBP é denotada por  $LBP_{P,R}^{riu2}$ ,

sendo  $P$  o número de vizinhos, e  $R$  o valor do raio. A referência “riu2” reflete o uso da rotação invariante uniforme, e o número de transições valendo, no máximo, 2.

O descritor LBP, ao longo dos anos foi desenvolvido em várias aplicações como classificação de texturas, segmentação de textura, reconhecimento facial, recuperação de imagens.

### 3.3 Local Fuzzy Pattern (LFP)

Como foi dito anteriormente, o método TU tem a desvantagem de gerar muitos códigos. O LBP resolve esse problema, diminuindo a quantidade de códigos gerados de 6561 para 256. Mas, essa redução faz com o método se torne menos robusto contra ruídos, devido ao resultado da sua comparação levar os valores binários (0 e 1) e não a quantidade real da diferença entre os valores dos pixels.

Para minimizar os defeitos desse problema, Boaventura e Gonzaga (2007) apresentaram um novo método para a detecção de bordas em imagens baseada no conceito de números fuzzy, a *Fuzzy Number Edge Detector (FUNED)*. O qual inspirou a Viera et al. (2012) para propor o *Local Fuzzy Pattern (LFP)* como uma metodologia para análise de texturas baseada em números fuzzy, capaz de lidar com problemas que envolvem graus de incerteza e ambiguidade.

Um conjunto fuzzy é um par  $(U; \mu)$ , no qual  $U$  é um conjunto e  $\mu : U \rightarrow [0, 1]$ . Para cada elemento  $x \in U$ , o valor  $\mu(x)$  é denominado grau de pertinência de  $x$  em  $(U; \mu)$ . Para um conjunto finito  $U = \{x_1, x_2, \dots, x_n\}$ , o conjunto fuzzy é denotado por  $\{\mu(x_1) | x_1, \dots, \mu(x_n) | x_n\}$ ,  $x$  é chamado de membro do conjunto fuzzy se  $0 < \mu(x) < 1$ . A função  $\mu(x)$  é chamada função de pertinência do conjunto fuzzy  $(U; \mu)$  (VIEIRA et al., 2012a).

O LFP é um descritor de textura local que determina o grau de pertinência (*membership degree*) de cada pixel da região de interesse, considerando a intensidade dos tons de cinza dos pixels como elementos de um conjunto fuzzy (VIERA et al., 2012).

Tome uma janela representando o micro padrão de tamanho  $W \times W$  e uma matriz de pesos  $P$  representada por  $P(k, l)$ . O pixel central é dado por  $g(i, j)$  e uma função de pertinência relaciona os vizinhos ao pixel central  $f_{g(i,j)}$ . O descritor LFP é dado por:

$$\hat{\mu}(g(i, j)) = \frac{\sum_{k=1}^W \sum_{l=1}^W f_{g(i,j)}(g(k, l)) \cdot P(k, l)}{\sum_{k=1}^W \sum_{l=1}^W P(k, l)} \quad (3.8)$$

na qual  $\hat{\mu}(g(i, j))$  é o grau de pertinência do pixel central à região definida pela janela  $W$ . O valor final é dado pela média ponderada dos valores de pertinência individuais de cada pixel. Na Figura 3.5 exemplifica-se a geração de um código LFP.

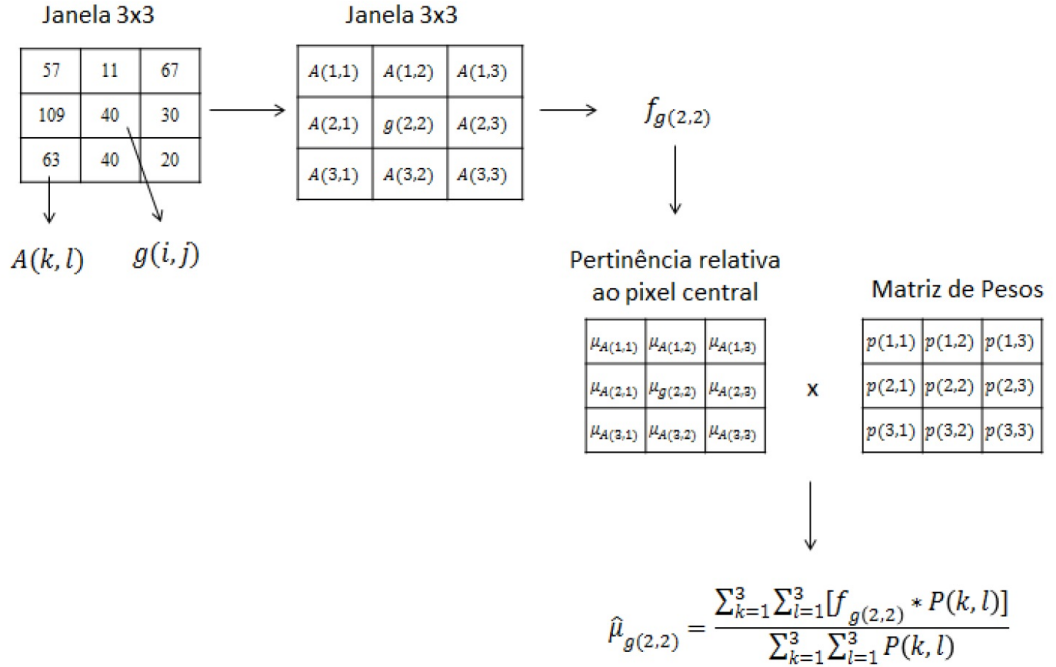


Figura 3.5: Geração de um código LFP. Fonte (TRAVAINI, 2015)

A função de pertinência pode ser definida pelo usuário durante a aplicação do método, segundo Viera (2013), é por isso, que sua função de pertinência é heurística e não única. Este método por utilizar uma representação por números fuzzy, é paramétrico e passível de otimização dos seus parâmetros. O LFP foi proposto com três principais funções de pertinência que geram por sua vez os métodos a seguir:

- **LFP-sigmoid.** A função de pertinência que descreve o LFP-s é a função Sigmoide, dada pela Equação 3.9.

$$f_{g(i,j)}(A(k, l)) = \frac{1}{1 + e^{-\frac{[A(k,l) - g(i,j)]}{\beta}}}, \quad (3.9)$$

no qual  $\beta$  é a inclinação da curva sigmoide,  $A(k, l)$  são os pixels da vizinhança e  $g(i, j)$  é o pixel central. A matriz de pesos para esta função de uma vizinhança  $3 \times 3$  é dada por:

$$P = \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix}.$$

A Figura 3.6 apresenta um exemplo do cálculo do LFP-s para uma amostra de  $3 \times 3$  pixels.

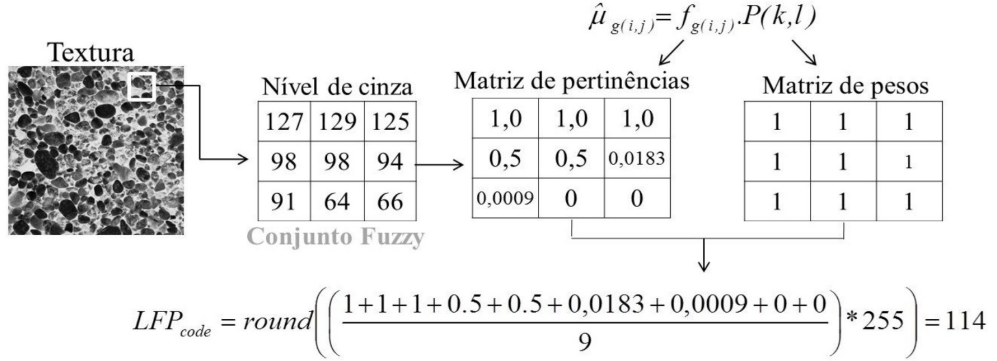


Figura 3.6: Cálculo do código LFP. Fonte (VIERA, 2013)

- LFP-*triangular*. Usando uma função de pertinência triangular e simétrica, descrita pela Equação 3.10

$$f_{g(i,j)} = \max\left(0.1 - \frac{|g(i,j) - A(k,l)|}{\delta}\right), \quad (3.10)$$

em que  $A(k,l)$  são os pixels na vizinhança  $W \times W$ ,  $\delta$  é o espalhamento de número fuzzy e a matriz de pesos é da forma:

$$P = \begin{bmatrix} 1 & 1 & 1 \\ 1 & 0 & 1 \\ 1 & 1 & 1 \end{bmatrix}.$$

O valor zero do pixel central desta matriz de pesos deve-se ao fato de que em (BOAVENTURA, 2010) o pixel central da região analisada é excluído do cálculo de sua pertinência.

- LFP-*Gaussian*. Outra função de pertinência é a função Gaussiana dada pela Equação 3.11

$$f_{g(i,j)} = \exp^{-\frac{[A(k,l)-g(i,j)]^2}{\sigma}}, \quad (3.11)$$

onde  $\sigma$  é o desvio padrão.

Como o descritor LFP gera valores no intervalo  $[0, 1]$  e, assim é necessário convertê-los para um esquema de nível de cinza de 8-bits. Desta forma, cada valor do grau de pertinência é multiplicado por 255 e então é arredondado o resultado final, como pode ser visto na Figura 3.6.

### 3.4 Local Mapped Pattern (LMP)

Inicialmente, o *Local Mapped Pattern* (LMP) foi feito com a finalidade de analisar texturas, recuperar imagens e auxiliar no reconhecimento de faces (FERRAZ; PEREIRA; GONZAGA, 2014). A técnica LMP consiste na suavização dos níveis de cinza de uma imagem a partir do mapeamento feito através de uma função pré-definida  $f_{g(i,j)}$ . Desta forma, para cada pixel  $g(i, j)$ , calcula-se o mapeamento relativo  $h(g(i, j))$  em função de uma região específica de vizinhos de  $g(i, j)$ . O método LMP foi desenvolvido a partir do método LFP. Ferraz, Pereira e Gonzaga (2014) propõem que este mapeamento, definido em uma vizinhança  $W \times W$ , seja determinado pela equação 3.8, a mesma que é para o descritor LFP, como mostra a Figura 3.7.

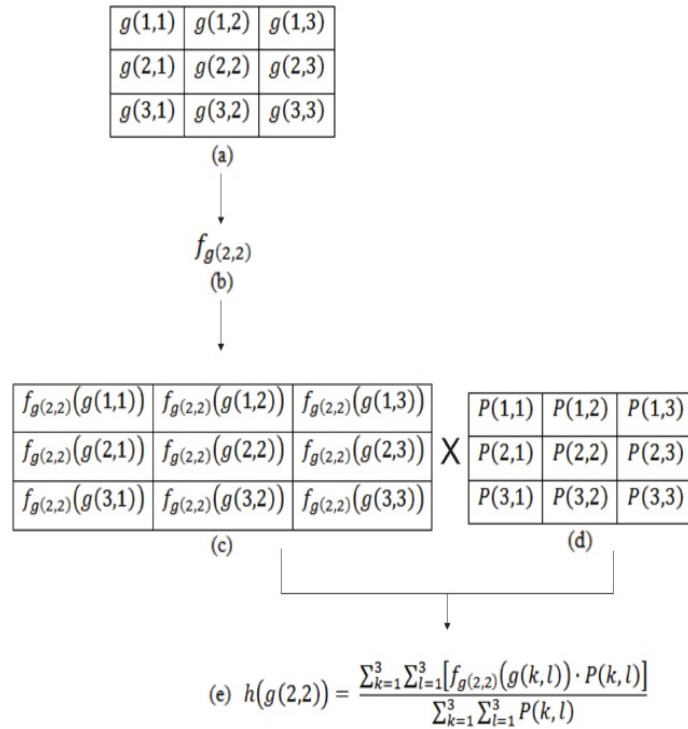


Figura 3.7: Cálculo do mapeamento relativo do pixel central. Fonte (CONTRERAS; BOAVENTURA; BOAVENTURA, 2015)

A Equação 3.8 é uma generalização de outros métodos presentes na literatura. O próprio LBP pode ser escrito como caso particular dessa proposta. Para tanto, toma-se a função  $f_{g(i,j)}$  como a função degrau de Heaviside ( $H$ ), dada pela equação 3.12:

$$H[A(k,l) - g(i,j)] = \begin{cases} 1, & \text{se } A(k,l) - g(i,j) \geq 0, \\ 0, & \text{se } A(k,l) - g(i,j) < 0. \end{cases} \quad (3.12)$$


Considerando o  $LBP_{8,1}$  ( $W = 3$ ), a matriz de pesos é dada por:

$$P = \begin{bmatrix} 1 & 2 & 4 \\ 8 & 0 & 16 \\ 32 & 64 & 128 \end{bmatrix}.$$


A proposta desta técnica é atenuar a ação ruidosa presente nas imagens de texturas fazendo uso de aplicações responsáveis por suavizar as altas frequências presentes nas vizinhanças de um mesmo pixel. Para utilizar o padrão LMP é necessário definir uma aplicação responsável pela suavização da imagem. Como na abordagem LBP é feita uma comparação *crisp* (0 ou 1) (Equação 3.6) entre os pixels, usando como aplicação de suavização a função degrau de Heaviside, há uma perda de informação, que é acentuada pela presença de ruído nas bases de texturas envolvidas, relacionada com a quantidade real da diferença entre os valores dos pixels. Assim, definindo uma função sigmoide, dada pela Equação 3.13, a qual é capaz de captar nuances que abordagens com formulação analítica não são capazes. Desta forma, a suavidade da função sigmoide transmite uma abordagem mais realística para o padrão LMP atenuando, assim, a perda de informação sofrida pela presença de ruído na imagem.

$$f_{g(i,j)}(A(k,l)) = \frac{1}{1 + e^{-\frac{[A(k,l) - g(i,j)]}{\lambda}}}, \quad (3.13)$$

onde  $\lambda \in [0, 1]$  e  $[A(k,l) - g(i,j)]$  são as diferenças em tons de cinza dentro da vizinhança  $W \times W$  centrada em  $g(i,j)$ . A variável  $\lambda$  pode ser ajustada empiricamente para que o método seja otimizado e, portanto, possua uma maior acurácia.



(a) Função degrau de Heaviside para o descritor LBP



(b) Função sigmoide para o descritor LMP

Figura 3.8: Funções de Mapeamento do nível de cinza pela Equação 3.8. Fonte (FERRAZ; PEREIRA; GONZAGA, 2014)

Desta forma, a matriz de pesos  $P$ , descrita na Equação 3.8, será uma matriz  $W \times W$ , com  $W = 3$ , dada por:

$$P = \begin{bmatrix} 1 & 1 & 1 \\ 1 & 0 & 1 \\ 1 & 1 & 1 \end{bmatrix}. \quad (3.14)$$

Logo, o padrão LMP de um pixel  $g(i, j)$  é obtido através da Equação 3.15

$$LMP(g(i, j)) = \frac{\sum_{(k,l) \in I \setminus \{(i,j)\}} (f_{g(i,j)} g(k, l))}{8}, \quad (3.15)$$

na qual,  $I = \{(k, l) : k = i - 1, i, i + 1 \text{ e } l = j - 1, l, l + 1\}$ .

Como a imagem da função sigmoide está compreendida entre 0 e 1, pela Equação 3.15, tem-se  $LMP(g(i, j)) \in (0, 1)$ . Então, com o intuito de obter um padrão com valores inteiros em  $[0, 255]$ , o método faz uso da versão normalizada do valor obtido.

### 3.5 Considerações finais

Neste capítulo apresentou-se alguns descritores de textura presentes na literatura. O LBP superou ao TU, no fato de gerar uma quantidade menor de códigos. Os métodos LMP e LFP são mais eficazes na descrição de textura, devido ao fato de que se utiliza-se funções de pertinência adequadas, pode-se extrair características significantes da imagem, para atenuar a presença de ruídos; o que no caso do LBP não acontece por fazer uso da *comparação crisp*.

---

No próximo capítulo encontra-se apresentado os padrões que fazem uso de mais de uma escala, entre eles o *Multi-Scale Local Binary Pattern* (MSLBP) o *Multi-Scale Local Mapped Pattern* (MSLMP), cujos nome devem-se aos padrões nos quais seu desenvolvimento foi baseado. Além disso, introduz-se uma modificação do MSLMP, a qual é feita mudando a Matriz de Pesos.

## CAPÍTULO 4

# PADRÕES EM MULTIESCALA

Neste capítulo é descrito a metodologia utilizada para a análise e classificação de texturas, utilizando vizinhanças mais abrangentes (OJALA; PIETIKÄINEN; MÄENPÄÄ, 2002), ou seja vizinhanças superiores a  $3 \times 3$ , como foi visto no capítulo anterior. O método no qual esse estudo centra-se é o descritor chamado de *Multi-scale local Mapped Pattern* (CONTRERAS; BOAVENTURA; BOAVENTURA, 2015). Diferentes Matrizes de Pesos são utilizadas para avaliar seu desempenho, a fim de se obter melhores resultados (melhor Sensibilidade ( $S\%$ )) em comparação com outros métodos presentes na literatura.

Nas seções a seguir, são descritos os principais métodos presentes na literatura definidos em abordagens multi-escalas. Tradicionalmente, as aplicações desses métodos estão voltadas ao reconhecimento e análise de texturas. No entanto, há trabalhos recentes nos quais tais métodos são empregados na detecção de impressões digitais fraudulentas (CONTRERAS, 2015).

### 4.1 O Multi-Scale Local Binary Pattern (MSLBP)

Como foi visto na seção 3.2, o padrão  $LBP_{P,R}$  é definido pela Equação 3.5. Em (MÄENPÄÄ; PIETIKÄINEN, 2003) é sugerido que se faça uso de extrações sucessivas do padrão  $LBP_{P,R}$  (Figura 4.1) na mesma imagem. Cada extração é caracterizada de acordo com o raio  $R$ . Métodos que fazem uso de estratégia semelhante são conhecidos como multiescalas (*multi-scale*) por apresentarem mais de uma etapa (escala) na extração da informação requerida.




Figura 4.1: Vizinhanças circular de um pixel em multiescala. Fonte (OJALA; PIETIKÄINEN; MÄENPÄÄ, 2002).

Jia et al. (2014) apresentam duas variações de um método que faz uso de várias escalas e é conhecido como *Multi-Scale Local Binary Pattern* (MSLBP). A primeira versão, denominada no trabalho por MSLBP1, consiste de diversas extrações do padrão  $LBP_{8,R_n}$  de uma imagem suavizada por filtragem Gaussiana. Já a segunda versão, denominada no trabalho por MSLBP2, consiste de extrair o padrão  $LBP_{8,1}$  de regiões as quais foram suavizadas por filtros de média, isto é, o cálculo do padrão  $LBP_{8,1}$  não é feito utilizando-se pixels diretamente, mas fazendo uso de regiões que contém a média dos respectivos níveis de cinza dos pixels, como mostra a Figura 4.2.

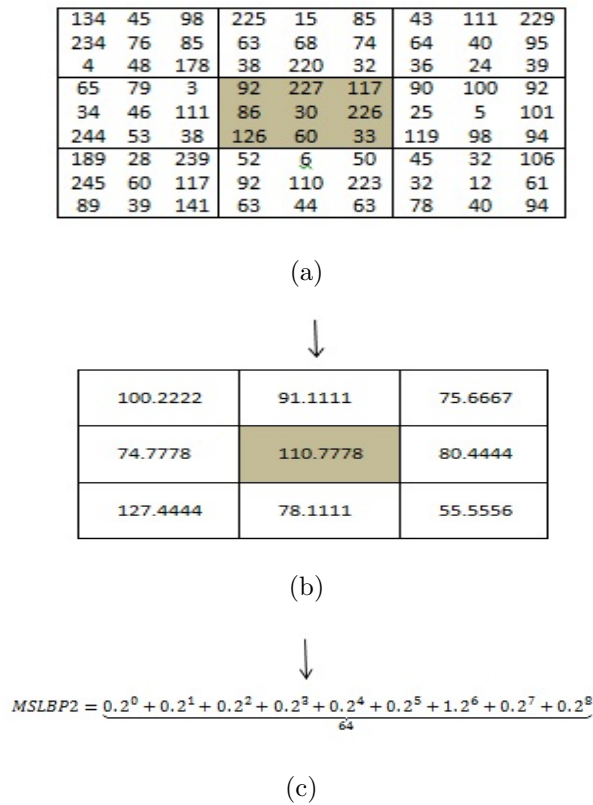


Figura 4.2: Exemplo do cálculo do MSLBP2 de uma matriz  $9 \times 9$ : (a) Matriz  $9 \times 9$ , (b) Média das regiões  $3 \times 3$  da matriz original, (c): cálculo do MSLBP2

O método MSLBP1 consiste em extrair o padrão  $LBP_{8,R_n}$  da imagem suavizada por um filtro Gaussiano de tamanho  $G_n$ , dado pela equação 4.3, na  $n$ -ésima escala. Sendo que o desenvolvimento de cada escala se faz de acordo com a mudança dos valores dos raios. Tal mudança ocorre respeitando a distribuição ótima com relação à aplicação de filtros gaussianos apresentada em (MÄENPÄÄ; PIETIKÄINEN, 2003). A figura 4.3 apresenta vizinhanças de um pixel central que são quantizadas por oito amostras ( $P = 8$ ), formando oito setores que distam  $R_n$  do pixel central. A necessidade da filtragem Gaussiana presente no método se dá para que todos os pixels contidos nos círculos da Figura 4.3 sejam levados em consideração no cálculo do micropadrão. Com a ação de um filtro passa-baixa, a informação de uma amostra é coletada em uma maior área, que no caso são os círculos da Figura 4.3. O raio externo da “área útil” das amostras formadas por círculos na Figura 4.3, que funciona como valor auxiliar no cálculo do raio  $R_n$  da operação  $LBP_{8,R_n}$ , é dado pela equação 4.1.

$$r_n = r_{n-1} \cdot \left( \frac{2}{1 - \sin \frac{\pi}{8}} - 1 \right), \quad n \in \{2, \dots, N\}, \quad (4.1)$$

na qual  $N$  é o número de escalas utilizadas no método.

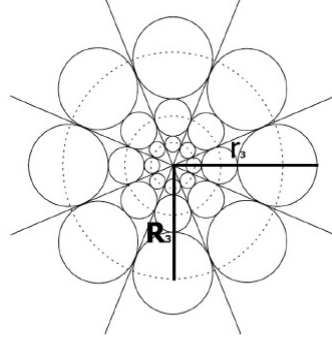


Figura 4.3: Distribuição ótima dos raios do padrão MSLBP1 com respeito à redução de redundância da informação capturada pelo padrão. Fonte: (MÄENPÄÄ; PIETIKÄINEN, 2003)

Nota-se que é necessário que  $r_n \geq 1$  para todo  $n$ , pois trata-se de um raio responsável por estabelecer distâncias entre um pixel central e a borda de suas vizinhanças  $3 \times 3$ . Portanto,  $r_1$  é definido por 1.5, que é a menor distância entre o centro e a borda de uma vizinhança  $3 \times 3$ .

Os raios das operações  $LBP_{8,R_n}$  são escolhidos de forma que as áreas efetivas (círculos da Figura 4.3) das amostras estejam em contato. Conseqüentemente, define-se  $R_n$  ( $n \geq 2$ ) como sendo o ponto médio entre  $r_n$  e  $r_{n-1}$ :

$$R_n = \frac{r_n + r_{n-1}}{2}, \quad n \in \{2, \dots, N\}. \quad (4.2)$$

Como  $R_n$  representa a distância entre o pixel central e os pixels de suas vizinhanças, desta forma,  $R_1$  é definido por 1, que é a menor distância entre o pixel central e os elementos de sua vizinhança  $3 \times 3$ .

Os valores  $r_n$  também são utilizados para calcular o tamanho das janelas utilizadas nos filtros Gaussianos, como mostra a equação 4.3:

$$G_n = 2 \cdot \left\lceil \frac{r_n - r_{n-1}}{2} \right\rceil + 1, \quad n \in \{2, \dots, N\}, \quad (4.3)$$

na qual a função  $\lceil \cdot \rceil : \mathbb{R} \rightarrow \mathbb{N} \cup \{0\}$  é a função responsável por associar a um valor o menor inteiro que seja maior que o mesmo.

Em cada nível, o valor  $\delta_n$  necessário para a aplicação do filtro Gaussiano é dado pela equação 4.4:

$$\delta_n = \frac{G_n}{\sqrt{-2 \ln(0.05)}}, \quad n \in \{2, \dots, N\}. \quad (4.4)$$

## 4.2 Multi-Scale Local Mapped Pattern (MSLMP)

Em (ZHU; WANG, 2012) vê-se que apenas a extração do padrão LBP de uma imagem o torna extremamente vulnerável a ruídos. Jia et al. (2014) resolveram este problema amenizando com a utilização de filtros passa-baixas antes de extrair versões de LBP. A partir desta ideia, em (CONTRERAS; BOAVENTURA; BOAVENTURA, 2015) foi estudado uma abordagem que é extensão multiescala do método LMP, onde a proposta é atenuar a ação ruidosa presente nas imagens de texturas, para o qual utiliza-se aplicações responsáveis por suavizar as altas frequências presentes nas vizinhanças de um mesmo pixel. Tais vizinhanças são representadas por raios que aumentam conforme o nível do processo, caracterizando o método como multiescala, que já se mostrou robusto na resolução de problemas envolvendo a detecção de impressões digitais fraudulentas (JIA et al., 2014; JIA et al., 2013)

Como visto na seção 3.4, para utilizar o padrão LMP é necessário definir uma função  $f_{g(i,j)}$  responsável pela suavização da imagem. Como na abordagem LBP é feita uma comparação *crisp* (0 ou 1) entre os pixels usando como aplicação de suavização a função degrau de Heaviside (Figura 3.8 (a)), há uma perda de informação, que é acentuada pela presença de ruído nas bases envolvidas, relacionada com a quantidade real da diferença entre os valores dos pixels. Assim, pretende-se, definindo  $f_{g(i,j)}$  como função sigmoide (Figura 3.8 (b)), dada pela Equação 3.13, capaz de captar nuances que abordagens com formulação analítica não são, em geral, eficientes.

A aplicação de filtros gaussianos realizada no método MSLBP1 de Jia et al. (2014) torna-se desnecessária neste método, uma vez que a suavidade da função sigmoide transmite uma abordagem mais realista para o padrão LMP atenuando, assim, a perda de informação sofrida pela presença de ruído na imagem.

Assim, em (CONTRERAS; BOAVENTURA; BOAVENTURA, 2015), a evolução de

cada escala se faz de acordo com o aumento do tamanho da dimensão das vizinhanças do pixel  $g(i, j)$ . Desta forma, a matriz de pesos  $P_n$ , descrita na Equação 4.6, é dada por uma matriz  $W_n \times W_n$  na  $n$ -ésima escala do método, com  $W_n$  dado pela Equação 4.5:

$$W_n = 2 \cdot \lceil R_n \rceil + 1, \quad (4.5)$$

na qual,  $R_n$  pode ser calculado através da equação 4.2.

$$P_n = \begin{bmatrix} 1 & 0 & \cdots & 0 & 1 & 0 & \cdots & 0 & 1 \\ 0 & 0 & & 0 & 0 & 0 & & 0 & 0 \\ \vdots & \vdots & & \vdots & \vdots & \vdots & & \vdots & \vdots \\ 0 & 0 & & 0 & 0 & 0 & & 0 & 0 \\ 1 & 0 & \cdots & 0 & 0 & 0 & \cdots & 0 & 1 \\ 0 & 0 & & 0 & 0 & 0 & & 0 & 0 \\ \vdots & \vdots & & \vdots & \vdots & \vdots & & \vdots & \vdots \\ 0 & 0 & & 0 & 0 & 0 & & 0 & 0 \\ 1 & 0 & \cdots & 0 & 1 & 0 & \cdots & 0 & 1 \end{bmatrix}. \quad (4.6)$$

A matriz  $P_n$  foi construída da maneira apresentada na equação 4.6 a fim de se assegurar que a abordagem proposta, assim como no método MSLBP1, fizesse uso de apenas 8 amostras pertencentes à vizinhança dos pixels em cada uma das escalas. Desta forma, a presença dos valores nulos em  $P_n$  é responsável por desconsiderar o valor de outros pixels presentes na vizinhança do pixel central. Deste modo, os outros  $W_n^2 - 8$  pixels são desconsiderados no cálculo do padrão MSLMP.

Logo, o padrão MSLMP de um pixel  $g(i, j)$  na  $n$ -ésima escala do método é obtido através da Equação 4.7:

$$\begin{aligned} MSLMP(g(i, j)) &= \frac{1}{8} (f_{g(i, j)}(A(1, 1)) + f_{g(i, j)}(A(1, \lceil R_n \rceil + 1)) + f_{g(i, j)}(A(1, W_n)) \\ &\quad + f_{g(i, j)}(A(\lceil R_n \rceil + 1, 1)) + f_{g(i, j)}(A(\lceil R_n \rceil + 1, W_n)) \\ &\quad + f_{g(i, j)}(A(W_n, 1)) + f_{g(i, j)}(A(W_n, \lceil R_n \rceil + 1)) \\ &\quad + f_{g(i, j)}(A(W_n, W_n))). \end{aligned}$$

Em forma mais geral:

$$MSLMP(g(i, j)) = \frac{\sum_{(k,l) \in I_n \setminus \{(i,j)\}} (f_{g(i,j)}(g(k, l)))}{8}, \quad (4.7)$$

na qual,  $I_n = \{(k, l) : k = i - \lceil R_n \rceil, i, i + \lceil R_n \rceil \text{ e } l = j - \lceil R_n \rceil, j, j + \lceil R_n \rceil\}$ .

Como a imagem da função sigmoide está compreendida entre 0 e 1, pela Equação 4.7, tem-se  $MSLMP(g(i, j)) \in (0, 1)$ . Então, com o intuito de obter um padrão com valores inteiros em  $[0, 255]$ , o método faz uso da versão normalizada do valor obtido pela Equação 4.7, isto é, o padrão final extraído do pixel  $g(i, j)$  é o valor  $N_{MSLMP}$  calculado por:

$$N_{MSLMP}(g(i, j)) = \lceil 255 \cdot MSLMP(g(i, j)) \rceil. \quad (4.8)$$

Pela Equação 4.8, os padrões  $N_{MSLMP}$  geram valores inteiros contidos no intervalo  $[0, 255]$ .

### 4.3 Extração de características

Como foi mencionado ao final da seção 3.2, alguns desses valores representam uma classe especial chamada de *uniform patterns*. Tal classe é responsável, na grande maioria das vezes, pela caracterização de mais de 90% de toda informação que se pretende extrair. Define-se como *uniform pattern* o valor  $U \in [0, 255] \cap \mathbb{Z}$  tal que  $U$  quando escrito na sua forma binária  $(b_1b_2b_3b_4b_5b_6b_7b_8)_2$ , com  $b_i \in \{0, 1\}$ , satisfaça a relação 4.9:

$$|b_1 - b_8| + \sum_{i=2}^8 |b_i - b_{i-1}| \leq 2. \quad (4.9)$$

Em (JIA et al., 2014) afirma-se que, tomadas  $P$  amostras, existem  $(P - 1) \cdot P + 2$  *uniform patterns*. Como  $P = 8$  no método anterior, então existem 58 valores entre  $[0, 255]$  que satisfazem a desigualdade 4.9.

Para extração de características, primeiro constrói-se em cada escala o histograma dos valores normalizados gerados pelo padrão  $N_{MSLMP}$  extraído das imagens em questão. Posteriormente, tomam-se as taxas de ocorrências dos 58 *uniform patterns* no histograma construído na  $n$ -ésima escala seguidas da soma das taxas restantes para formar o vetor  $x_n = (x_1, x_2, \dots, x_N) \in \mathbb{R}^{59}$ . Finalmente, o vetor de características extraído da imagem é o vetor  $v = norm(x)$  cujo número de coordenadas é  $N \cdot 59$ , no qual  $N$  é o número de escalas

utilizadas e  $norm(\cdot)$  é a função responsável pela normalização apresentada na Equação 4.10:

$$norm(y) = \frac{1}{\max(y) - \min(y)}(y - \min(y)). \quad (4.10)$$

### 4.3.1 Matrizes de Pesos utilizadas para o teste do método

Observa-se que a matriz  $P_n$  definida na Equação 4.6, leva em consideração amostragens que ficam fora da vizinhança do pixel central (tendo em consideração a Figura 4.3, a qual mostra a distribuição ótima dos Raios, utilizados para o cálculo da dimensão da matriz de Pesos  $W_n$ ), considerando-se o Raio  $R_n$  definido na Equação 4.2, devido ao fato de considerar amostragens nos cantos (pixels mais distantes do pixel central).

Apesar do método estudado ter obtido bons resultados em trabalhos anteriores de Contreras, Boaventura e Boaventura (2015) e Contreras (2015), mais análises devem ser conduzidas visando sua viabilidade, como um descritor robusto para a análise e classificação de texturas. Para tal análise foram propostas diferentes matrizes de Pesos  $P1, P2, \dots, P6$ . As matrizes  $P1, P2, \dots, P5$ , assim como a matriz  $P_n$  definida na Equação 4.6, assegura que a abordagem fizesse uso de apenas 8 amostragens pertencentes à vizinhança do pixel para cada escala.

A construção das matrizes foram feitas, de tal forma a espalhar as 8 amostragens de cada escala para obter uma melhor distribuição com respeito ao pixel central dentro da vizinhança. Tal espalhamento foi feito fazendo deslocamentos em distintas direções dos pontos da vizinhança da matriz original  $P_n$  (Equação 4.6). A ideia principal de utilizar essas matrizes baseia-se em extrair informação mais significativa das amostras analisadas, e assim gerar um vetor de características, o qual é utilizado para classifica-las com melhor precisão.

As matrizes a seguir estão em dimensão de  $11 \times 11$  ( $n=11$ ), mas podem ser expandidas para vizinhanças maiores. De uma maneira mais geral, essas matrizes são representadas no Apêndice A. Portanto o método MSLMP será avaliado com cada uma das matrizes de Pesos apresentadas abaixo.

A matriz de Pesos  $P1$  (Equação 4.11) foi construída fazendo deslocamentos para à direita, na primeira escala deslocamos cada ponto da vizinhança uma posição para à direita, para a segunda escala deslocamos cada ponto da vizinhança duas posições para à direita, para a terceira escala deslocamos cada ponto da vizinhança três posições para à

direita, e assim por diante.

Ao descritor de textura local que utiliza a matriz de Pesos  $P1$  definida na Equação 4.11, é denotado por MSLMP1, o que significa o Padrão Mapeado Localmente em Multiescala (MSLMP) utilizando a matriz de Pesos  $P1$ , com dimensão  $11 \times 11$ :

$$P1 = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 1 & 0 & 0 & 1 & 0 & 0 \\ 0 & 1 & 0 & 0 & 1 & 0 & 1 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 & 1 & 1 & 1 & 1 & 1 & 0 & 0 \\ 1 & 0 & 1 & 0 & 1 & 0 & 1 & 0 & 1 & 0 & 1 \\ 0 & 0 & 0 & 1 & 1 & 1 & 1 & 1 & 1 & 0 & 0 \\ 0 & 1 & 0 & 0 & 1 & 0 & 1 & 0 & 0 & 1 & 0 \\ 0 & 0 & 1 & 0 & 0 & 1 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 1 \end{bmatrix}. \quad (4.11)$$

A matriz de Pesos  $P2$  (Equação 4.12) foi construída fazendo deslocamentos para à esquerda, na primeira escala deslocamos cada ponto da vizinhança uma posição para à esquerda, para a segunda escala deslocamos cada ponto da vizinhança uma posição para à esquerda, para a terceira escala deslocamos cada ponto da vizinhança uma posição para à esquerda, e assim por diante. Ou seja, para cada escala sempre deslocamos cada ponto da vizinhança uma posição para à esquerda.

Ao descritor de textura local que utiliza a matriz de Pesos  $P2$  definida na Equação 4.12, é denotado por MSLMP2, o que significa o Padrão Mapeado Localmente em Multiescala (MSLMP) utilizando a matriz de Pesos  $P2$ , com dimensão  $11 \times 11$ :

$$P2 = \begin{bmatrix} 0 & 1 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 1 & 0 & 0 & 1 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 1 & 0 & 1 & 0 & 0 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 0 & 0 & 1 & 0 & 1 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 1 & 0 & 0 & 1 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 1 & 1 \end{bmatrix}. \quad (4.12)$$

As demais matrizes foram construídas fazendo deslocamento tanto para à direita como para esquerda, de tal maneira que as 8 amostragem sempre fiquem bem espalhadas. Pode-se para uma dada escala utilizar algum deslocamento à direita e para a próxima escala utilizar algum deslocamento à esquerda, ou seja fazemos deslocamentos mistos (direita e esquerda).

Ao descritor de textura local que utiliza a matriz de Pesos  $P3$  definida na Equação 4.13, é denotado por MSLMP3, o que significa o Padrão Mapeado Localmente em Multiescala (MSLMP) utilizando a matriz de Pesos  $P3$ , com dimensão  $11 \times 11$ :

$$P3 = \begin{bmatrix} 0 & 0 & 0 & 1 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 1 & 0 & 0 & 0 & 0 \\ 1 & 0 & 0 & 1 & 0 & 1 & 0 & 1 & 0 & 0 & 1 \\ 0 & 0 & 1 & 0 & 1 & 1 & 1 & 0 & 1 & 0 & 0 \\ 0 & 1 & 0 & 1 & 1 & 0 & 1 & 1 & 0 & 1 & 0 \\ 0 & 0 & 1 & 0 & 1 & 1 & 1 & 0 & 1 & 0 & 0 \\ 1 & 0 & 0 & 1 & 0 & 1 & 0 & 1 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 1 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \end{bmatrix}. \quad (4.13)$$

Ao descritor de textura local que utiliza a matriz de Pesos  $P4$  definida na Equação 4.14, é denotado por MSLMP4, o que significa o Padrão Mapeado Localmente em Multiescala (MSLMP) utilizando a matriz de Pesos  $P4$ , com dimensão  $11 \times 11$ :

$$P4 = \begin{bmatrix} 0 & 1 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 1 & 0 & 1 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 1 & 0 & 1 & 0 & 1 \\ 0 & 0 & 0 & 1 & 1 & 1 & 1 & 1 & 1 & 0 & 1 \\ 0 & 0 & 1 & 0 & 1 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 1 & 1 & 1 & 1 & 1 & 1 & 0 & 0 \\ 1 & 0 & 1 & 0 & 1 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 1 & 0 & 1 & 0 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 1 & 0 \end{bmatrix}. \quad (4.14)$$

Ao descritor de textura local que utiliza a matriz de Pesos  $P5$  definida na Equação 4.15, é denotado por MSLMP5, o que significa o Padrão Mapeado Localmente em Multiescala (MSLMP) utilizando a matriz de Pesos  $P5$ , com dimensão  $11 \times 11$ :

$$P5 = \begin{bmatrix} 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 & 1 & 0 & 1 & 0 & 0 & 0 & 1 \\ 0 & 1 & 0 & 1 & 0 & 1 & 0 & 1 & 0 & 1 & 0 \\ 0 & 0 & 1 & 0 & 1 & 1 & 1 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 1 & 0 & 1 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 1 & 1 & 1 & 0 & 1 & 0 & 0 \\ 0 & 1 & 0 & 1 & 0 & 1 & 0 & 1 & 0 & 1 & 0 \\ 1 & 0 & 0 & 0 & 1 & 0 & 1 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \end{bmatrix}. \quad (4.15)$$

A principal diferença entre as matrizes definidas anteriormente, é que em cada uma delas a “área útil” (Figura 4.3) das amostras não está na mesma posição, e portanto a área analisada é maior, e assim a classificação de texturas pode ser alterada.

Observa-se que a matriz de Pesos  $P2$  definida na Equação 4.12 tem melhor distribuição entre as 8 amostragens levados em consideração para cada escala. A matriz de Pesos  $P2$  (Equação 4.12) para cada escala, considera os 8 pixels mais próximos à vizinhança do pixel central, portanto mostra maior similitude à distribuição ótima da Figura 4.3.

Ao descritor de textura local que utiliza a matriz de Pesos  $P6$ , é denotado por MSLMP6, o que significa o Padrão Mapeado Localmente em Multiescala (MSLMP) utilizando a matriz de Pesos  $P6$ .

Essa última matriz é um pouco diferente das demais, aqui não só foram utilizadas apenas 8 amostras para cada escala, em cada escala as amostras aumentam de tamanho, mas sem considerar o pixel central da matriz. A construção desta matriz encontra-se detalhada a seguir:

- Se  $R_1 = 1$ , então pela Equação 4.5 temos que  $W_1 = 3$  e

$$P6_1 = \begin{bmatrix} 1 & 1 & 1 \\ 1 & 0 & 1 \\ 1 & 1 & 1 \end{bmatrix}.$$

- Se  $R_2 = 2$ , então pela Equação 4.5 temos que  $W_2 = 5$  e

$$P6_2 = \begin{bmatrix} 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 0 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \end{bmatrix}.$$

- Se  $R_3 = 3$ , então pela Equação 4.5 temos que  $W_3 = 7$  e

$$P6_3 = \begin{bmatrix} 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 0 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 \end{bmatrix}.$$

- Se  $R_4 = 4$ , então pela Equação 4.5 temos que  $W_4 = 9$  e

$$P6_4 = \begin{bmatrix} 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 0 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \end{bmatrix}.$$

- Se  $R_5 = 5$ , então pela Equação 4.5 temos que  $W_5 = 11$  e

$$P6_5 = \begin{bmatrix} 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 0 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \end{bmatrix}. \quad (4.16)$$

e assim sucessivamente.

## 4.4 Considerações finais

Como foi dito, anteriormente, o objetivo de analisar o descritor MSMLP, é avaliar seu desempenho do descritor para a análise e classificação de amostras de texturas. Neste capítulo foi apresentado o padrão que faz uso de mais de uma escala e que tem como objetivo auxiliar a classificação de imagens de texturas. Para avaliar seu bom desempenho foram introduzidas diferentes matrizes de Pesos, as quais foram testadas e mostraram resultados bons (melhor valor de Sensibilidade) em relação a outros padrões presentes na literatura. No próximo capítulo são exibidos e discutidos os resultados obtidos com a aplicação das metodologias apresentadas neste capítulo.

## CAPÍTULO 5

# RESULTADOS EXPERIMENTAIS

Neste capítulo são apresentados os experimentos realizados utilizando a abordagem de extração de características através do MSLMP com cada uma das matrizes de Pesos apresentadas no capítulo anterior.

### 5.1 Base de dados

Para avaliação de desempenho dos descritores estudados foram realizados testes com imagens da base do Álbum de Brodatz, que é composta por imagens digitalizadas a partir do Álbum de Brodatz (1966), amplamente utilizada em pesquisas na área de visão computacional. O experimento utiliza 112 imagens de texturas sintéticas e naturais. Cada imagem de textura é considerada como uma classe com dimensão de  $640 \times 640$  pixels. Para cada classe são extraídas 10 amostras aleatórias, assim, totalizam-se para o experimento 1120 imagens. Para o processo de classificação foram realizados testes com diferentes tamanhos de amostras extraídas, desde  $45 \times 45$  pixels até  $90 \times 90$  pixels, aumentando a quantidade de pixels de 5 em 5.

Alguns exemplos de imagens do Álbum de Brodatz são apresentados na Figura 5.1




Figura 5.1: Texturas presentes no álbum de Brodatz

## 5.2 Processo de avaliação e classificação

De todas as amostras de texturas, geradas a partir da base do Álbum de Brodatz, foram extraídos os micropadrões do MSLMP utilizando as distintas matrizes de pesos apresentadas na subseção 4.3.1 do Capítulo 4 e, em seguida, foram gerados os respectivos vetores de características.

A comparação entre esses vetores de características foi feita através de medidas de distâncias. Diversas medidas podem ser utilizadas, tais como a distância euclidiana, a distância de Mahalanobis, a distância Chessboard, dentre outras. Neste trabalho, para o processo de classificação foi utilizada a comparação entre vetores de características com a distância Chi Quadrado (PELE; WERNAN, 2010). A distância Chi Quadrado compara todos os bins de um histograma. A distância Chi Quadrado  $\chi^2$  entre dois vetores  $v_i, w_j \in \mathbb{R}^n$ , é dada pela Equação 5.1:

$$\chi^2(v_i, w_j) = \frac{1}{2} \sum_{k=1}^n \frac{(v_{i,k} - w_{j,k})^2}{v_{i,k} + w_{j,k}}, \quad (5.1)$$

na qual  $v_i$  representa o vetor de características da  $i$ -ésima amostra que está sendo avaliada e  $w_j$  representa o vetor de características da  $j$ -ésima amostra do conjunto que está sendo comparada com a amostra avaliada.

Utilizando-se validação cruzada *leave-one-out*, foram comparados os vetores de características gerados de cada amostra com o restante das amostras do conjunto (1119 amostras) conforme ilustrado na Figura 5.2.

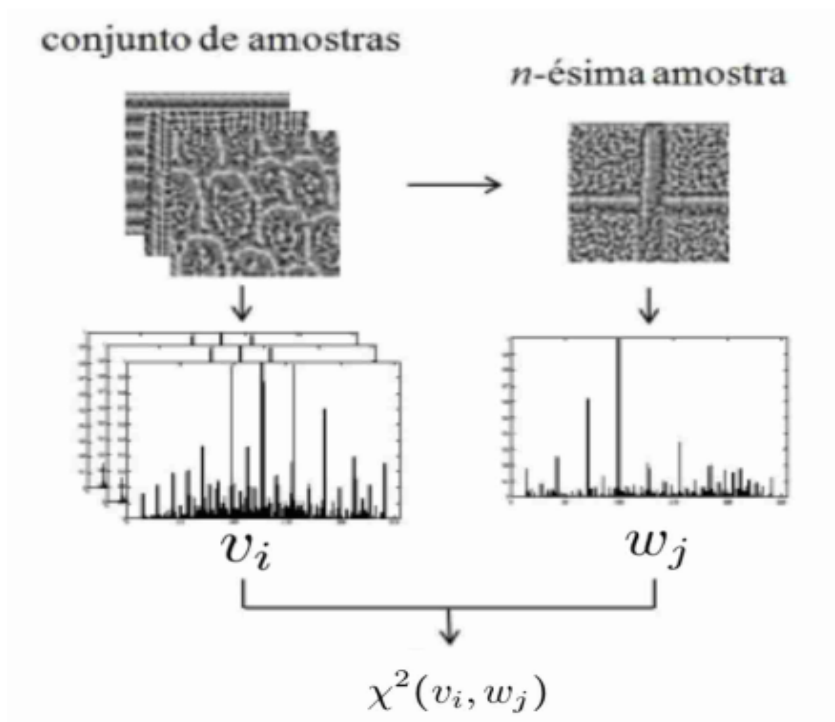


Figura 5.2: Processo de classificação

Uma amostra é considerada corretamente classificada se pertencer a mesma classe da amostra de teste, para a qual obteve a menor distância, ou seja, se o menor valor de distância Chi-quadrado for encontrado quando a amostra avaliada for comparada com as demais amostras da mesma classe. Os resultados das classificações são armazenados em uma matriz de confusão e, então, é feito o cálculo da Sensibilidade ( $S$ ), Equação 2.1, alcançada para cada descritor (VIEIRA et al., 2012b).

Neste trabalho, o descritor *Multi-Scale Local Mapped Pattern* avaliado com a matriz de pesos 4.6 (CONTRERAS, 2015) foi denotado por MSLMP. E para diferenciar este descritor quando mudamos a matriz de pesos, foi utilizada a notação  $MSLMP_n$ , o qual denota o descritor *Multi-Scale Local Mapped Pattern* avaliado com a matriz de pesos  $P_n$  ( $n = 1, \dots, 6$ ). Tais descritores foram testados utilizando até 5 escalas  $MSLMP_{n-x}$  com  $x = 1, \dots, 5$ , vejamos alguns exemplos da notação usada neste trabalho:

- MSLMP\_4 significa, o descritor MSLMP utilizando a matriz de Pesos (Equação 4.6) com 4 escalas.
- MSLMP3\_1 significa, o descritor MSLMP utilizando a matriz de Pesos  $P3$  (Equação 4.13) com 1 escala.
- MSLMP5\_2 significa, o descritor MSLMP utilizando a matriz de Pesos  $P5$  (Equação 4.15) com 2 escalas

Os códigos computacionais foram implementados em Matlab (MATHWORKS, 2015) R2015b na versão 64 bits, que fornece uma ampla biblioteca de funções, facilitando a programação dos modelos, que demandariam maior tempo se fossem desenvolvidos em outra linguagem de programação.

Na Tabela 5.1 é possível observar os resultados dos melhores descritores presentes na literatura até o momento: o *Local Binary Pattern* (LBP), o *Local Fuzzy Pattern - Sigmoide* (LFP - s), o *Local Fuzzy Pattern - Triangular* (LFP - t) e a técnica MSLMP $_x$ , que é a técnica MSLMP dada pela Equação 4.7 com a matriz de Pesos 4.6, e  $x$  é o número de escalas utilizadas. Os rótulos da primeira fila indicam o tamanho das amostras ( $45 \times 45$  pixels,  $50 \times 50$  pixels, ...,  $90 \times 90$  pixels).

	$45 \times 45$	$50 \times 50$	$55 \times 55$	$60 \times 60$	$65 \times 65$	$70 \times 70$	$75 \times 75$	$80 \times 80$	$85 \times 85$	$90 \times 90$
LBP	75,9%	82,9%	84,2%	85,9%	87,1%	89,7%	91,4%	92,7%	94,6%	94,6%
LFP-s	81,6%	87,2%	89,2%	91,9%	93,0%	94,8%	96,2%	96,5%	98,1%	97,9%
LFP-t	72,0%	78,2%	80,5%	84,4%	85,4%	88,6%	89,6%	91,9%	93,2%	94,1%
MSLMP_1	80,98%	85,09%	86,52%	91,70%	93,75%	94,91%	94,64%	95,36%	96,79%	96,79%
MSLMP_2	84,82%	88,75%	89,91%	93,21%	94,55%	95,71%	95,27%	96,52%	97,14%	98,13%
MSLMP_3	85,54%	89,29%	89,19%	93,13%	94,46%	96,07%	95,09%	96,34%	97,68%	97,78%
MSLMP_4	85,63%	88,39%	89,19%	91,70%	93,21%	96,07%	95,00%	95,80%	97,23%	97,32%
MSLMP_5	83,57%	87,68%	89,38%	91,34%	92,59%	95,54%	95,00%	95,98%	96,70%	97,05%

Tabela 5.1: Sensibilidade obtida a partir de diversos descritores presentes na literatura. Fonte (CONTRERAS; BOAVENTURA; BOAVENTURA, 2015)

## 5.3 Resultados obtidos

Nesta seção são apresentados os resultados experimentais da análise do descritor estudado (MSLMP), testado com as diferentes matrizes de Pesos, os quais foram obtidos realizando testes computacionais com as 1120 amostras geradas do Álbum de Brodatz.

O objetivo é realizar uma comparação entre os resultados obtidos com o MSLMP e os apresentados na literatura científica (CONTRERAS; BOAVENTURA; BOAVENTURA, 2015), (VIERA, 2013).

Para que a análise do descritor MSLMP possa ser apresentado neste trabalho, é necessário a definição dos parâmetros  $\lambda$  que aparece na Equação 3.13. Este parâmetro define a qualidade do mapeamento feito na imagem quanto à questão da amenização do ruído presente nas imagens testadas, a fim de se alcançar o melhor desempenho. Para cada matriz testada são exibidos os melhores valores de sensibilidade encontrados para os parâmetros otimizados, os valores dos demais parâmetros podem ser vistos nos Apêndices B, C, D, E, F e G.

A Tabela 5.2 exibe os valores de sensibilidade obtidos pelo descritor MSLMP1.

	45 × 45	50 × 50	55 × 55	60 × 60	65 × 65	70 × 70	75 × 75	80 × 80	85 × 85	90 × 90
MSLMP1_1	75,45%	79,29%	84,20%	88,13%	89,64%	90,71%	92,95%	95,09%	95,54%	96,25%
MSLMP1_2	83,84%	87,86%	90,54%	91,96%	93,75%	95,18%	95,98%	96,34%	96,96%	97,59%
MSLMP1_3	87,86%	90,71%	93,66%	94,20%	95,18%	95,18%	97,05%	97,14%	97,68%	97,68%
MSLMP1_4	90,71%	92,41%	92,86%	94,91%	95,63%	96,70%	98,04%	97,95%	97,86%	98,30%
MSLMP1_5	93,66%	95,00%	95,18%	96,25%	97,05%	97,95%	98,93%	98,30%	98,48%	98,39%

Tabela 5.2: Sensibilidade obtida ao testar o descritor MSLMP1

Observe na Tabela 5.2 que o melhor valor de sensibilidade obtido foi de 98,93% (amostras de tamanho 75 × 75 pixels e 5 escalas), superando os resultados da Tabela 5.1.

Através, da Tabela 5.2 observa-se que:

- Fazendo uso de uma escala, o descritor MSLMP1 supera o descritor LBP para quase todas as amostras, exceto para aqueles de tamanho 45 × 45 pixels e 50 × 50 pixels; e não supera o descritor LFP-s (que é o descritor que apresenta melhor sensibilidades no trabalho (VIERA, 2013)) nem o descritor MSLMP em nenhuma das escala.
- Para duas escalas o MSLMP1 supera o descritor LBP e para o descritor LFP-s supera apenas para amostras de tamanho 45 × 45 pixels até 70 × 70 pixels.
- Utilizando três escalas o descritor MSLMP1 supera quase todos os descritores, exceto para amostras de tamanho de 70 × 70 pixels e 90 × 90 pixels. Nos casos em que supera há um ganho de até 3,75%, é o caso das amostras de tamanho 55 × 55 pixels.
- Para quatro e cinco escalas já supera todos os descritores.

Portanto, é suficiente usar três escalas para que a técnica proposta com a matriz de pesos 4.11 seja robusta. Em resumo, houve melhora de desempenho do descritor MSLMP1. Este fato pode ser visualizado na Tabela 5.3, onde observa-se o ganho do valor de sensibilidade (S%) do MSLMP1 com respeito aos descritores LFP-s e MSLMP.

	45 × 45	50 × 50	55 × 55	60 × 60	65 × 65	70 × 70	75 × 75	80 × 80	85 × 85	90 × 90
LFP-s	12,06%	9,5%	5,98%	4,35%	4,05%	3,15%	2,73%	1,8%	0,38%	0,49%
MSLMP	8,03%	5,71%	5,27%	3,04%	2,5%	1,88%	3,66%	1,78%	0,8%	0,26%

Tabela 5.3: Ganho de sensibilidade do descritor MSLMP1

Outro ponto a ser observado é que o descritor LBP necessita de uma amostra de tamanho  $90 \times 90$  pixels para alcançar um valor de sensibilidade que o MSLMP1\_5 já alcança com uma amostra menor com  $55 \times 55$  pixels de tamanho. Da mesma forma o descritor LFP-s necessita de uma amostra de tamanho  $90 \times 90$  pixels para alcançar um valor de sensibilidade que o MSLMP1\_5 já alcança com uma amostra menor com  $70 \times 70$  pixels de tamanho.

Observa-se também, que para amostra de tamanho  $45 \times 45$  pixels,  $50 \times 50$  pixels e  $55 \times 55$  pixels, o descritor já proporciona uma melhora na classificação utilizando 4 e 5 escalas, superando os descritores aqui analisados. Para amostras de tamanhos maiores também apresenta uma melhoria, mas o ganho de sensibilidade para amostras de tamanho  $85 \times 85$  pixels e  $90 \times 90$  pixels não é muito significativo, devido ao fato que para amostras de  $45 \times 45$  pixels, o valor de sensibilidade já é muito bom.

Como foi dito anteriormente, o MSLMP é um descritor paramétrico, o que quer dizer que alguns parâmetros devem ser ajustados. A escolha dos melhores valores para  $\lambda$ , utilizados na função de mapeamento (a função sigmoide dada pela Equação 3.13) é feita por meio de treinamento, onde o processo de classificação é repetido variando-se o parâmetro em questão, para obter uma melhor sensibilidade. Nos experimentos executados, a faixa de possíveis valores para  $\lambda$  foi definida entre  $(0, 1]$ , onde os valores dos intervalos foram definidos empiricamente.

Na Tabela 5.4 são apresentados os valores dos parâmetros  $\lambda$  otimizados para o descritor MSLMP1 para cada escala (cada linha representa cada escala, a primeira linha representa a primeira escala, e assim por diante), ou seja, essa tabela mostra o valor do parâmetro  $\lambda$  no qual o MSLMP1 alcança o melhor desempenho.

	45 × 45	50 × 50	55 × 55	60 × 60	65 × 65	70 × 70	75 × 75	80 × 80	85 × 85	90 × 90
MSLMP1_1	0,95	1	0,7	0,705	1	0,955	0,85	1	1	0,755
MSLMP1_2	0,805	0,855	0,7	0,8	0,95	0,9	0,5	0,5	0,55	0,705
MSLMP1_3	1	0,65	0,755	0,9	0,95	0,7	0,955	0,75	0,95	0,805
MSLMP1_4	0,95	1	0,95	0,705	0,705	0,35	0,65	0,75	0,955	0,85
MSLMP1_5	1	0,65	1	0,55	0,75	1	0,55	0,6	0,65	0,7

Tabela 5.4: Parâmetros otimizados  $\lambda$  da função de mapeamento

Observe na Tabela 5.4 e no apêndice B que os melhores valores para  $\lambda$  estão no intervalo  $[0,7, 1]$ . As tabelas 5.2 e 5.4 mostram a melhor sensibilidade obtida do descritor MSLMP1 com seu respectivo  $\lambda$  utilizado na função de mapeamento. Ou seja o MSLMP1\_4 alcança melhor sensibilidade 95,63% com amostras de tamanho  $65 \times 65$  utilizando  $\lambda = 0,705$ .

Agora mostra-se os resultados obtidos para as outras matrizes de Pesos, os valores de Sensibilidade foram muito próximos, como pode ser observado nas Tabelas a seguir:

A Tabela 5.5 exhibe os valores de sensibilidade obtidos pelo descritor MSLMP2. A Tabela 5.6 exhibe os valores dos parâmetros otimizados para o descritor.

	45 × 45	50 × 50	55 × 55	60 × 60	65 × 65	70 × 70	75 × 75	80 × 80	85 × 85	90 × 90
MSLMP2_1	75,36%	79,29%	84,20%	86,70%	89,64%	90,71%	92,86%	95,18%	95,54%	96,25%
MSLMP2_2	83,84%	87,86%	90,54%	91,96%	93,48%	95,18%	95,98%	96,43%	96,96%	97,59%
MSLMP2_3	86,79%	90,18%	93,93%	93,75%	95,45%	95,18%	96,79%	96,96%	97,68%	98,04%
MSLMP2_4	90,18%	91,96%	94,02%	94,55%	95,89%	96,61%	98,39%	97,77%	97,86%	98,30%
MSLMP2_5	93,75%	95,09%	95,18%	96,61%	97,23%	98,03%	98,75%	98,48%	98,84	98,39%

Tabela 5.5: Sensibilidade obtida ao testar o descritor MSLMP2

	45 × 45	50 × 50	55 × 55	60 × 60	65 × 65	70 × 70	75 × 75	80 × 80	85 × 85	90 × 90
MSLMP2_1	0,950	1,000	0,700	0,700	1,000	0,955	0,850	0,700	1,000	0,755
MSLMP2_2	0,805	0,855	0,700	0,800	1,000	0,900	0,500	0,450	0,550	0,705
MSLMP2_3	1,000	1,000	0,650	1,000	1,000	0,500	0,950	0,650	0,350	0,350
MSLMP2_4	0,500	1,000	0,950	0,650	0,950	0,700	0,755	0,705	0,700	0,705
MSLMP2_5	0,705	1,000	0,705	0,755	0,805	0,700	0,955	0,600	0,600	0,755

Tabela 5.6: Parâmetros otimizados  $\lambda$  da função de mapeamento

	45 × 45	50 × 50	55 × 55	60 × 60	65 × 65	70 × 70	75 × 75	80 × 80	85 × 85	90 × 90
LFP-s	12,15%	9,59%	5,98%	4,71%	4,23%	3,23%	2,55%	1,98%	0,74%	0,49%
MSLMP	8,12%	5,80%	5,27%	3,4%	2,68%	1,96%	3,48%	1,96%	1,16%	0,26%

Tabela 5.7: Ganho de sensibilidade do descritor MSLMP2

A Tabela 5.8 exibe os valores de sensibilidade obtidos pelo MSLMP3. A Tabela 5.9 exibe os valores dos parâmetros otimizados para o descritor.

	45 × 45	50 × 50	55 × 55	60 × 60	65 × 65	70 × 70	75 × 75	80 × 80	85 × 85	90 × 90
MSLMP3_1	75,45%	79,29%	84,20%	86,70%	89,64%	90,71%	92,95%	95,18%	95,54%	96,25%
MSLMP3_2	81,88%	87,59%	89,46%	91,16%	93,21%	95,00%	96,34%	96,43%	97,14%	97,77%
MSLMP3_3	85,54%	90,00%	93,21%	94,11%	94,73%	95,00%	96,88%	97,14%	97,50%	97,77%
MSLMP3_4	90,80%	92,68%	92,95%	94,73%	95,80%	96,88%	98,13%	97,59%	98,13%	98,21%
MSLMP3_5	92,50%	94,55%	95,18%	95,80%	97,05%	97,86%	98,75%	98,30%	98,66%	98,57%

Tabela 5.8: Sensibilidade obtida ao testar o descritor MSLMP3

	45 × 45	50 × 50	55 × 55	60 × 60	65 × 65	70 × 70	75 × 75	80 × 80	85 × 85	90 × 90
MSLMP3_1	0,950	1,000	0,700	0,700	1,000	0,955	0,850	0,700	1,000	0,755
MSLMP3_2	1,000	0,750	0,700	0,705	0,650	0,705	0,550	0,950	0,650	0,650
MSLMP3_3	1,000	0,755	0,550	0,755	0,955	0,650	0,700	0,855	0,705	0,650
MSLMP3_4	0,650	1,000	0,755	0,650	0,750	0,550	0,700	0,705	0,950	0,650
MSLMP3_5	0,950	1,000	1,000	0,700	0,955	1,000	0,700	0,650	0,650	0,750

Tabela 5.9: Parâmetros otimizados  $\lambda$  da função de mapeamento

	45 × 45	50 × 50	55 × 55	60 × 60	65 × 65	70 × 70	75 × 75	80 × 80	85 × 85	90 × 90
LFP-s	10,9%	9,05%	5,98%	3,9%	4,05%	3,06%	2,55%	1,8%	0,56%	0,67%
MSLMP	6,87%	5,26%	5,27%	2,59%	2,5%	1,79%	3,48%	1,78%	0,98%	0,44%

Tabela 5.10: Ganho de sensibilidade do descritor MSLMP3

A Tabela 5.11 exibe os valores de sensibilidade obtidos pelo MSLMP4. A Tabela 5.12 exibe os valores dos parâmetros otimizados para o descritor.

	45 × 45	50 × 50	55 × 55	60 × 60	65 × 65	70 × 70	75 × 75	80 × 80	85 × 85	90 × 90
MSLMP4_1	75,45%	79,29%	84,20%	88,13%	89,64%	90,71%	92,95%	95,18%	95,54%	96,25%
MSLMP4_2	83,84%	87,86%	90,54%	91,96%	93,75%	95,09%	95,98%	96,52%	96,96%	97,59%
MSLMP4_3	86,25%	89,73%	93,93%	93,75%	94,91%	95,54%	97,23%	96,96%	97,86%	97,77%
MSLMP4_4	89,38%	92,41%	91,43%	93,93%	96,16%	95,98%	97,59%	97,86%	97,86%	98,04%
MSLMP4_5	92,95%	94,02%	95,36%	95,54%	96,70%	97,68%	98,30%	98,04%	98,39%	98,48%

Tabela 5.11: Sensibilidade obtida ao testar o MSLMP4

	45 × 45	50 × 50	55 × 55	60 × 60	65 × 65	70 × 70	75 × 75	80 × 80	85 × 85	90 × 90
MSLMP4_1	0,950	1,000	0,700	0,705	1,000	0,955	0,850	0,700	1,000	0,755
MSLMP4_2	0,805	0,750	0,700	0,800	0,950	0,955	0,500	0,450	0,550	0,705
MSLMP4_3	0,955	0,700	0,705	0,750	0,750	0,075	0,900	0,805	0,955	0,700
MSLMP4_4	0,750	0,955	0,700	0,750	0,750	0,550	0,700	0,705	0,950	0,650
MSLMP4_5	0,650	1,000	1,000	0,650	0,755	1,000	0,805	1,000	0,650	0,750

Tabela 5.12: Parâmetros otimizados  $\lambda$  da função de mapeamento

	45 × 45	50 × 50	55 × 55	60 × 60	65 × 65	70 × 70	75 × 75	80 × 80	85 × 85	90 × 90
LFP-s	11,35%	8,52%	6,16%	3,64%	3,7%	2,88%	2,1%	1,54%	0,29%	0,58%
MSLMP	7,32%	4,73%	5,45%	2,33%	2,15%	1,61%	3,03%	1,52%	0,71%	0,35%

Tabela 5.13: Ganho de sensibilidade do descritor MSLMP4

A Tabela 5.14 exibe os valores de sensibilidade obtidos pelo MSLMP5. A Tabela 5.15 exibe os valores dos parâmetros otimizados para o descritor.

	45 × 45	50 × 50	55 × 55	60 × 60	65 × 65	70 × 70	75 × 75	80 × 80	85 × 85	90 × 90
MSLMP5_1	75,45%	79,29%	84,20%	88,13%	89,64%	90,71%	92,95%	95,18%	95,54%	96,25%
MSLMP5_2	81,88%	87,59%	89,46%	91,16%	93,21%	95,00%	96,34%	96,43%	97,14%	97,59%
MSLMP5_3	86,43%	90,45%	93,75%	93,39%	94,82%	94,64%	96,43%	96,96%	97,41%	97,59%
MSLMP5_4	88,30%	91,61%	92,41%	94,20%	95,45%	95,80%	97,95%	97,59%	97,23%	97,86%
MSLMP5_5	92,14%	94,02%	95,09%	95,63%	96,52%	97,41%	98,30%	98,04%	98,30%	98,30%

Tabela 5.14: Sensibilidade obtida ao testar o descritor MSMLP5

	45 × 45	50 × 50	55 × 55	60 × 60	65 × 65	70 × 70	75 × 75	80 × 80	85 × 85	90 × 90
MSLMP5_1	0,950	1,000	0,700	0,705	1,000	0,955	0,85	0,700	1,000	0,755
MSLMP5_2	1,000	0,750	0,700	0,705	0,650	0,705	0,550	0,950	0,650	0,700
MSLMP5_3	0,650	0,650	0,705	0,950	0,955	1,000	0,755	0,755	0,900	0,550
MSLMP5_4	1,000	1,000	0,700	0,755	0,950	0,750	0,650	0,550	0,950	0,700
MSLMP5_5	1,000	1,000	0,705	0,950	0,955	0,750	0,850	0,755	1,000	0,955

Tabela 5.15: Parâmetros otimizados  $\lambda$  da função de mapeamento

	45 × 45	50 × 50	55 × 55	60 × 60	65 × 65	70 × 70	75 × 75	80 × 80	85 × 85	90 × 90
LFP-s	10,54%	8,52%	5,89%	3,73%	3,52%	2,61%	2,1%	1,54%	0,2%	0,4%
MSLMP	6,51%	4,73%	5,18%	2,42%	1,97%	1,34%	3,03%	1,52%	0,62%	0,17%

Tabela 5.16: Ganho de sensibilidade do descritor MSLMP5

A Tabela 5.17 exibe os valores de sensibilidade obtidos pelo MSLMP6. A Tabela 5.18 exibe os valores dos parâmetros otimizados para o descritor.

	45 × 45	50 × 50	55 × 55	60 × 60	65 × 65	70 × 70	75 × 75	80 × 80	85 × 85	90 × 90
MSLMP6_1	75,45%	79,29%	84,20%	88,13%	89,64%	90,71%	92,95%	95,18%	95,54%	96,25%
MSLMP6_2	79,20%	85,89%	88,04%	91,43%	92,95%	95,27%	96,70%	96,96%	97,23%	97,68%
MSLMP6_3	85,00%	88,57%	92,77%	94,11%	95,80%	96,34%	96,96%	97,5%	98,39%	98,39%
MSLMP6_4	88,75%	92,05%	93,93%	95,54%	96,61%	97,95%	98,39%	98,57%	98,66%	99,20%
MSLMP6_5	90,45%	92,14%	94,73%	96,16%	97,50%	97,77%	99,38%	98,66%	99,02%	99,11%

Tabela 5.17: Sensibilidade obtida ao testar o descritor MSMLP6

	45 × 45	50 × 50	55 × 55	60 × 60	65 × 65	70 × 70	75 × 75	80 × 80	85 × 85	90 × 90
MSLMP6_1	0,95	1	0,7	0,705	1	0,955	0,85	0,7	1	0,755
MSLMP6_2	1	0,9	1	1	0,95	1	0,955	1	0,955	0,705
MSLMP6_3	0,955	1	0,7	1	0,95	0,755	0,955	0,95	0,75	1
MSLMP6_4	0,955	1	1	0,955	0,95	0,95	0,6	0,95	1	0,95
MSLMP6_5	0,955	0,955	1	0,95	1	0,8	1	1	1	0,7

Tabela 5.18: Parâmetros otimizados  $\lambda$  da função de mapeamento

	45 × 45	50 × 50	55 × 55	60 × 60	65 × 65	70 × 70	75 × 75	80 × 80	85 × 85	90 × 90
LFP-s	8,85%	6,64%	5,53%	4,26%	4,5%	3,15%	3,18%	2,16%	0,92%	1,3%
MSLMP	4,82%	2,85%	4,82%	2,95%	2,95%	1,88%	4,11%	2,14%	1,34%	1,07%

Tabela 5.19: Ganho de sensibilidade do descritor MSLMP6

Observa-se que em todas as tabelas anteriores, o aumento do tamanho das amostras extraídas proporciona uma melhora na classificação (melhores valores de sensibilidade). Assim, analisando as tabelas para todas as matrizes de Pesos ( $P_1, P_2, \dots, P_6$ ) utilizando 4 e 5 escalas supera os demais descritores utilizados nessa comparação.

A Tabela 5.20 mostra os resultados dos descritores  $MSLMP_n$  para  $n = 1, \dots, 6$  com os melhores valores de sensibilidade, o qual foi obtido utilizando 5 escalas.

	$45 \times 45$	$50 \times 50$	$55 \times 55$	$60 \times 60$	$65 \times 65$	$70 \times 70$	$75 \times 75$	$80 \times 80$	$85 \times 85$	$90 \times 90$
MSLMP1_5	93,66%	95,00%	95,18%	96,25%	97,05%	97,95%	98,93%	98,30%	98,48%	98,39%
MSLMP2_5	93,75%	95,09%	95,18%	96,61%	97,23%	98,03%	98,75%	98,48%	98,84%	98,39%
MSLMP3_5	92,50%	94,55%	95,18%	95,80%	97,05%	97,86%	98,75%	98,30%	98,66%	98,57%
MSLMP4_5	92,95%	94,02%	95,36%	95,54%	96,70%	97,68%	98,30%	98,04%	98,39%	98,48%
MSLMP5_5	92,14%	94,02%	95,09%	95,63%	96,52%	97,41%	98,30%	98,04%	98,30%	98,30%

Tabela 5.20: Comparação dos descritores  $MSLMP$ 's

Observe na Tabela 5.20, que o descritor  $MSLMP_6$ , foi o descritor que apresentou desempenho inferior em apenas para amostras desde  $45 \times 45$  pixels até  $60 \times 60$  pixels, quando as amostras testadas têm tamanho superior, melhora seu desempenho, mas o tempo que utilizo ao testar as amostras é muito maior em comparação aos outros descritores, devido ao fato de utilizar matrizes com mais pontos. Quando compara-se as 5 primeiras filas, o descritor que alcançou maior sensibilidade é o descritor  $MSLMP_2$ .

## 5.4 Considerações finais

Neste capítulo foi abordada a metodologia utilizada para avaliação dos descritores  $MSLMP_n$  ( $n = 1, \dots, 6$ ) na descrição de texturas. Tais descritores foram comparados com outros descritores presentes na literatura. Também foi apresentada a base de dados utilizada.

O melhor desempenho foi apresentado pelo descritor  $MSLMP_2$ , o qual apresenta sensibilidade média superior à sensibilidade média dos outros métodos. Este descritor alcança sensibilidade superior devido ao fato de utilizar uma matriz de Pesos  $P_2$ , com melhor espalhamento das 8 amostragens da vizinhança do pixel limiarizado, para assim classificar as amostras com maior precisão.

Neste trabalho foi apresentado um estudo sobre a análise e a verificação da viabilidade do padrão mapeado localmente em multiescala (MSLMP), como um descritor utilizado para a classificação de texturas. Para tal fim, foi proposto uma análise do descritor, mediante a utilização de distintas matrizes de Pesos. Às variações do descritor MSLMP foram denotamos por  $MSLMP_n$  para a matriz de Pesos  $P_n$ .

Das 112 imagens de textura, do Álbum de Brodatz, foram extraídas 10 amostras aleatoriamente para cada classe. Após o processamento dessas imagens pelos diferentes descritores  $MSMLP_n$ , foram comparadas as taxas de acertos por meio da distância Chi-quadrado.

Como considerações finais, pode-se dizer que a contribuição deste trabalho foi apresentar uma validação do padrão MSLMP. Este descritor é um método robusto para a análise de textura, que permite ao usuário o ajuste de parâmetros dos valores de  $\lambda$  afim de proporcionar a melhora do desempenho do descritor no processo de descrição, e assim, uma classificação com boa precisão.

## 6.1 Sugestões para trabalhos futuros

Algumas propostas para continuidade das pesquisas sobre o MSLMP:

- avaliar o desempenho do descritor considerando a variação da rotação das imagens;
- técnicas mais precisas de otimização podem ser empregadas a fim de se estabelecer

um melhor valor para o parâmetro  $\lambda$  da função de mapeamento e com isso melhorar o desempenho do descritor;

- fazer uso do descritor para classificação de texturas específicas como por exemplo, reconhecimento Biométrico da Íris humana, reconhecimento de faces, entre outras.
- comparar com outros métodos de extração de características de textura que também utilizam abordagens em multiescala.

## REFERÊNCIAS BIBLIOGRÁFICAS

- ABE, S. *Support Vector Machines for Pattern Classifications*. [S.l.]: Kobe, Japão: Ed. Springer, 2005.
- AHONEN, T.; HADID, A.; PIETIKÄINEN, M. Face description with local binary patterns: Application to face recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 26, n. 12, p. 2037–2041, 2006.
- ALLILI, M. S.; ZIOU, D. Globally adaptive region information for automatic color-texture image segmentation. *Pattern Recognition Letters*, v. 28, n. 15, p. 1946–1956, 2007.
- BAGESTEIRO, L. D. *Classificação de Padrões Radiológicos por blocos em Imagens não segmentadas de Tomografia Computadorizada*. Dissertação (Mestrado) — Universidade Federal do Paraná, Curitiba, 2015.
- BALLARD, D. H.; BROWN, C. M. *Computer Vision*. [S.l.]: Prentice-Hall, 1982.
- BIMBO, A. D. *Visual Information Retrieval*. California: Morgan Kaufmann Publishers Inc. San Francisco, 1999.
- BINS, L. S.; ERTHAL, G. J.; FONSECA, L. M. G. Um método de classificação não supervisionada por regiões. *SIBGRAPI*, VI, p. 65–68, 1993.
- BLAKE, A.; MARINOS, C. Shape from texture: Estimation, isotropy and moments. *Artificial Intelligence*, v. 45, n. 3, p. 323–380, 1990.
- BOAVENTURA, I. A. G. *Números fuzzy em processamento de imagens digitais e suas aplicações na detecção de bordas*. Tese (Doutorado) — Escola de Engenharia de São Carlos - USP, São Carlos, 2010.
- BOAVENTURA, I. A. G.; GONZAGA, A. Border detection in digital images: An approach by fuzzy numbers. In: *Seventh International Conference on Intelligent Systems Design and Applications, ISDA*, p. 341–346, 2007.
- BRODATZ, P. *Texture: A photographic album for artists and designers*. New York: Dover Publications, 1966.

- BURRILL, J. H. P. Texture mapping of neurological magnetic resonance images. *3rd Year Individual Project, Imperial College of Science, Technology and Medicine, Department of Electrical and Electronic Engineering*, 1999.
- CASTLEMAN, K. R. *Digital Image Processing*. New Jersey: Prentice hall Inc., 1996.
- CAVALCANTE, I. Técnicas de processamento digital de imagens com java. p. 592–598, 2019.
- CHANG, Q.; ZHANG, B.; LIU, R. Texture analysis method for shape-based segmentation in medical image. In: *4th International Congress on Image and Signal Processing*, v. 3, p. 1146–1149, 2011.
- CHIERICI, C. E. O. *Classificação de texturas com diferentes orientações baseada em descritores locais*. Dissertação (Mestrado) — Departamento de Engenharia Elétrica e de Computação, Universidade de São Paulo, São Carlos, 2015.
- CHOI, Y. et al. Texture descriptors. In: *Manjunath, B. S.; Salembier, P.; Sikora, T. (Eds.) Introduction to MPEG-7: Multimedia Content Description Interface*. John Wiley and Sons, Ltd., Chichester, England, p. 213–230, 2002.
- COGGINS, J. M. *A Framework for Texture Analysis Based on Spatial Filtering*. Tese (Doutorado) — Michigan State University, East Lansing, Michigan, 1982.
- CONTRERAS, R. C. *Detecção de impressões digitais fraudulentas utilizando padrões mapeados localmente em multiescala*. Dissertação (Mestrado) — Universidade Estadual Paulista “Júlio de Mesquita Filho”, São José do Rio Preto, 2015.
- CONTRERAS, R. C.; BOAVENTURA, I. A. G.; BOAVENTURA, M. Multi-scale local mapped pattern for image texture analysis. *XI Workshop de Visão Computacional, 2015, São Carlos*, v. 11, 2015.
- CORTES, C.; VAPNIK, V. N. Support vector networks. *Machine Learning*, v. 20, n. 3, p. 273–296, 1995.
- DENG, Y. S.; MANJUNATH, B. S. Unsupervised segmentation of color-texture regions in images and video. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 23, n. 8, p. 800–810, 2001.
- DEWAELE, P.; GOOL, P. V.; OOSTERLINCK, A. Texture inspection with self-adaptive convolution filters. In: *Proceedings of the 9th International Conference on Pattern Recognition*, p. 56–60, 1988.
- FERRAZ, C. T.; PEREIRA, O.; GONZAGA, A. Feature description based on center-symmetric local mapped patterns. *Proceedings of the 29th Annual ACM Symposium on Applied Computing - SAC' 14*, p. 39–44, 2014.
- FORTEY, N. J. Image analysis in mineralogy and petrology: Mineral. *Mineral Mag.*, v. 59, p. 117–178, 1995.
- GABOR, D. Theory of communication. *Journal of the Institute of Electrical Engineers*, v. 93, p. 429–457, 1946.

- GELASCA, E. D. et al. Cortina: Searching a 10 million + image database. *Technical report*, 2007.
- GONZALEZ, R. C.; WOODS, R. E. *Digital image processing. 2.ed.* New Jersey: Prentice Hall, 2002.
- GUPTA, R.; UNDRILL, P. E. The use of texture analysis to identify suspicious masses in mammography. *University of Aberdeen, Foresterhill, Scotland. Department of Bio-Medical Physics and BioEngineering*, 1996.
- HARALICK, R. M. Statistical and structural approaches to texture. *In: Proceeding of the IEEE*, v. 67, n. 5, p. 786–804, 1979.
- HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. Textural features for image classification. *IEEE transactions on Systems, Man, and Cybernetics*, v. SMC-3, n. 6, p. 610–621, 1973.
- HAWKINS, J. K. Textural properties for pattern recognition. *In Picture Processing and Psychopictorics*, New York, USA, p. 128–136, 1970.
- HE, D. C.; WANG, L. Texture unit, texture spectrum, and texture analysis. *IEEE Transactions on Geoscience and Remote Sensing*, v. 28, p. 509–512, 1990.
- JAIN, A. K.; BHATTACHARJEE, S. K.; CHEN, Y. On texture in document images. *In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, p. 677–680, 1992.
- JAIN, A. K.; FARROKHANIA, F.; ALMAN, D. H. Texture analysis of automotive finishes. *In: Proceedings of SME Machine Vision Applications Conference*, p. 1–16, 1990.
- JI, Q.; ENGEL, J.; CRAINE, E. Texture analysis for classification of cervix lesions. *IEEE Trans. On Medical Imaging*, v. 19, n. 11, 2000.
- JIA, X. et al. Multi-scale local binary patterns with filters for spoof fingerprint detection. *Information Science*, v. 268, p. 91–102, 2014.
- JIA, X. et al. Multi-scale block local ternary patterns for spoof fingerprints vitality detection. *International Conference on Biometrics*, 2013.
- JULESZ, B. Textons, the elements of texture perception, and their interactions. *Nature*, v. 209, p. 91–97, 1981.
- KHADEMI, A.; KRISHNAN, S. Medical image texture analysis: A case study with small bowel, retinal and mammogram images. *In: Canadian Conference on Electrical and Computer Engineering*, p. 1949–1954, 2008.
- LEMOES, C.; REIS, J.; OLIVEIRA, W. *Indexação e Recuperação de Imagens por Conteúdo*. 2000.
- LIU, S. et al. Texture characteristic extraction of medical images based on pyramid structure wavelet transform. *In: International Conference on Computer Design and Applications*, v. 1, p. 342–345, 2010.

- LORENA, A. C.; CARVALHO, A. C. P. L. F. Uma introdução às support vector machines. *Revista de Informática Teórica e Aplicada*, v. 14, n. 2, p. 43–67, 2007.
- MÄENPÄÄ, T. et al. Robust texture classification by subsets of local binary patterns. *In: Proc. 15th International Conference on Pattern Recognition*, v. 3, p. 947–950, 2000.
- MÄENPÄÄ, T.; PIETIKÄINEN, M. Multi-scale binary patterns for texture analysis. *Machine Vision Group*, p. 885–892, 2003.
- MAGDA, S.; KRIEGMAN, D. Fast texture synthesis on arbitrary meshes. *In Proceedings of the 14th Eurographics workshop on Rendering (EGRW'03)*, p. 82–89, 2003.
- MARTINS, E. R. S. et al. Caracterização de lesões intersticiais de pulmão em radiograma de tórax utilizando análise local de textura. *Radiol Bras*, v. 38, n. 6, p. 421–426, 2005.
- MATHER, P. M. *Computer Processing of remotely-sensed images: an introduction*. London: John Wiley & Sons, 2004.
- NASCIMENTO, J. P. R. *Análise e Classificação de imagens baseadas em características de Textura utilizando Matrizes de Co-Ocorrência*. Dissertação (Mestrado) — Universidade Federal do Paraná, Curitiba, 2003.
- NIXON, M.; AGUADO, A. *Feature Extraction and Image Processing*. [S.l.]: 2nd Ed. Elsevier, 2008.
- OJALA, T.; PIETIKÄINEN, M. Texture classification. *Machine Vision and Media Processing Unt, University of Oulu, Finland*, 2013.
- OJALA, T.; PIETIKÄINEN, M.; HARDWOOD, D. A comparative study of texture measures with classification based on features distributions. *Pattern Recognition*, v. 29, p. 51–59, 1996.
- OJALA, T.; PIETIKÄINEN, M.; MÄENPÄÄ, T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *In: IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 24, n. 7, p. 971–987, 2002.
- PAGAMISSE, A.; DUTRA, L. V. Segmentação de texturas pela transformada wavelet diática direccional. *In: SIMPÓSIO DE CIÊNCIAS GEODÉSICAS DA GEOINFORMAÇÃO, 1*, p. 1–14, 2004.
- PEDRINI H.; SCHWARTZ, W. R. *Análise de Imagens Digitais: Princípios, Algoritmos e Aplicações*. São Paulo: Thomson Learning, 2008.
- PELE, O.; WERNAN, M. The quadratic-chi histogram distance family. *In: Proceeding of the 11th European conference on Computer Vision*, p. 749–762, 2010.
- PENTLAND, A.; PICARD, R. W. O.; SCLAROFF, S. Photobook: Tools for content-based manipulation of image database. *Proceeding of SPIE Conf. on Storage and Retrieval of Image and Video Databases*, v. 6, n. 2, p. 33–47, 1994.
- PIETIKÄINEN, M.; OJALA, T.; XU, Z. Rotation-invariant texture classification using feature distributions. *Pattern Recognition*, v. 33, p. 43–52, 2000.

- PRATT, W. K. *Digital Image Processing*. New York: John Wiley & Sons, 1991.
- RIGNOT, E.; KWOK, R. Extraction of textural features in sar images: Statistical model and sensitivity. *In: Proceedings of International Geoscience and Remote Sensing Symposium*, p. 1979–1982, 1990.
- ROSENFELD, A.; TROY, E. B. Visual texture analysis. *A Symposium on Feature Extraction and Selection in Pattern Recognition*, p. 115–124, 1970.
- RUI, Y.; HUANG, T. S.; CHANG, S. F. Image retrieval: Current techniques, promising directions, and open issues. *Journal of Visual Communication and Image Representation*, v. 10, p. 39–62, 1999.
- SILVA, F. P.; ROESE, P. B.; KINDLEIN, J. W. A texturização de produtos poliméricos e sua dependência com a seleção de materiais e os processos de fabricação. *UNOPAR Cient. Exatas Tecnol.*, v. 8, n. 1, p. 65–68, 2009.
- SILVA, J. B.; LIMA, L. C.; DANTAS, E. W. *Panorama da Geografia Brasileira II*. São Paulo: Annablume, ANPEGE, 2006.
- SKLANSKY, J. Image segmentation and feature extraction. *IEEE Transactions on Systems, Man and Cybernetics*, v. 13, n. 5, p. 907–916, 1978.
- SMEULDERS, A. W. M. et al. Content-based image retrieval at the end of the early years. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 22, n. 12, p. 1349–1380, 2000.
- SMITH, J. R.; CHANG, S. F. Visualseek: a fully automated content-based image query system. *In Proceeding of the 4th ACM international conference on Multimedia*, p. 87–98, 1996.
- SONKA, M.; HLAVAC, V.; BOYLE, R. *Image Processing, Analysis, and Machine Vision, Third Edition*. [S.l.]: Thomson Learning, 2008.
- TAMURA, H.; MORI, S.; YAMAWAKI, T. Textural features corresponding to visual perception. *IEEE transactions on Systems, Man, and Cybernetics*, v. 8, n. 6, p. 460–473, 1978.
- TOBIAS, O. J. et al. Automatic visual inspection using the co-occurrence approach. *In IEEE Midwest Symposium on Circuits and Systems*, v. 38, p. 154–157, 1996.
- TRAVAINI, J. N. *Descritores de Textura Local para Reconhecimento Biométrico da Íris Humana*. Dissertação (Mestrado) — Departamneto de Engenharia Elétrica e de Computação, Universidade de São Paulo, São Carlos, 2015.
- VALOIS, R. L. D.; ALBRECHT, D. G.; THORELL, L. G. Spatial-frequency selectivity of cells in macaque visual cortex. *Vision Res*, v. 22, p. 545–559, 1982.
- VAPNIK, V. N. *The nature of Statistical learning theory*. New York: Springer-Verlag, 1995.
- VIEIRA, R. T. et al. Image micro-pattern analysis using fuzzy number. *Conference on Graphics, Patterns and Images*, p. 87–93, 2012.

- VIEIRA, R. T. et al. Local fuzzy pattern: A new way for micro-pattern analysis. *Lecture Notes in Computer Science*, p. 602–611, 2012.
- VIERA, R. T. *Análise de micropadrões em imagens digitais baseada em números fuzzy*. Dissertação (Mestrado) — Departamento de Engenharia Elétrica e de Computação, Universidade de São Paulo, São Carlos, 2013.
- VIERA, R. T. G. et al. Uma nova proposta para análise de textura local por conjuntos fuzzy. In: *Anais do VIII Workshop de Visão Computacional, Goiânia*, 2012.
- WEBB, A. R. *Statistical Pattern Recognition*. [S.l.]: John Wiley & Sons, 2005.
- WEI, L. Y.; LEVOY, M. Fast texture synthesis using tree-structured vector quantization. In *Proceedings of the 27th annual conference on Computer graphics and interactive techniques (SIGGRAPH'00)*, p. 479–488, 2000.
- WOUMER, G. Van de; SCHEUDERS, P.; DYCK, D. V. Statistical texture characterization from discrete wavelet representation. *IEEE Transactions on Image Processing*, v. 8, n. 4, p. 592–598, 1999.
- WU, J. *Rotation Invariant Classification of 3D Surface Texture Using Photometric Stereo*. Tese (Doutorado) — Heriot-Watt University Edinburgh, 2003.
- XIE, X. A review of recent advances in surface defect detection using texture analysis techniques. *Electronic Letters on Computer Vision and Image Analysis*, v. 7, n. 3, p. 1–22, 2008.
- XU, G.; MA, S. Robust tile-based texture synthesis using texture element. In: *2010 International Conference on Electronics and Information Engineering*, v. 2, p. 179–183, 2010.
- ZHANG, J.; TAN, T. Brief review of invariant texture analysis methods. In: *Pattern Recognition*, v. 35, p. 735–747, 2002.
- ZHAO, G.; PIETIKÄINEN, M. Dynamic texture recognition using local binary patterns with an application to facial expressions. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 29, n. 6, p. 915–928, 2007.
- ZHU, C.; WANG, R. Local multiple patterns based multiresolution gray-scale and rotation invariant texture classification. *Information Science*, v. 187, n. 1, p. 93–108, 2012.
- ZUCKER, S. W.; KANT, K. Multiple-level representations for texture discrimination. In: *Proceedings of the IEEE Conference on Pattern Recognition and Image Processing*, p. 609–614, 1981.
- ZULIANG, A.; LIMIN, Z.; JIANTING, Z. A practical method of texture segmentation and transformation for radar image simulation. In: *2012 IEEE International Conference on Computer Science and Automation Engineering*, p. 311–317, 2012.



```

for i=1:row_max
    for j=1:col_max
        A=Input_Im(i:i+L-1,j:j+L-1);
        A=double(A);
        c=A(C,C);

        %% Calcula-se o padrao MSLMP1(c) multiplicado por 255
        %% u(x,c,lambda) = sigmf(x,[lambda c]); funcao sigmoide.

        resto = rem(R,2);

        if resto == 0
            LMP_Im(i,j)=255*(u(A(1,C-(R/2)),c,lambda)*P(1,C-(R/2))+
            u(A(1,L-(R/2)),c,lambda)*P(1,L-(R/2))+u(A(C-(R/2),1),c,
            lambda)*P(C-(R/2),1)+u(A(C-(R/2),L),c,lambda)*P(C-(R/2),L)
            +u(A(L-(R/2),1),c,lambda)*P(L-(R/2),1)+u(A(L-(R/2),L),c,
            lambda)*P(L-(R/2),L)+u(A(L,C-(R/2)),c,lambda)*P(L,C-(R/2))
            +u(A(L,L-(R/2)),c,lambda)*P(L,L-(R/2)))/S;

        else
            LMP_Im(i,j)=255*(u(A(1,1),c,lambda)*P(1,1)+u(A(1,C),c,
            lambda)*P(1,C)+u(A(1,L),c,lambda)*P(1,L)+u(A(C,1),c,
            lambda)*P(C,1)+u(A(C,L),c,lambda)*P(C,L)+u(A(L,1),c,
            lambda)*P(L,1)+u(A(L,C),c,lambda)*P(L,C)+u(A(L,L),c,
            lambda)*P(L,L))/S;
        end;
    end;
end;

%% Finalmente, tem-se o padrao N_{LMP}(g)
LMP_Im = round(LMP_Im);
end

```

## A.2 Rotina para o cálculo do MSLMP2

```

function LMP_Im = MSLMP2(Input_Im, lambda, R)

    if size(Input_Im, 3) == 3
        Input_Im = rgb2gray(Input_Im);
    end;

    R=ceil(R); %% R representa o raio da escala
    L = 2*R+1; %% L=W: tamanho da vizinhanca
    C=round(L/2);
    Input_Im = uint8(Input_Im);
    row_max = size(Input_Im, 1)-L+1;
    col_max = size(Input_Im, 2)-L+1;
    LMP_Im = zeros(row_max, col_max);

    %%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
    P = ones(L,L); %% Define-se a matriz de pesos
    P(C,C) = 0;
    S = 8; %% sum(sum(P));
    %%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

    for i=1:row_max
        for j=1:col_max
            A=Input_Im(i:i+L-1,j:j+L-1);
            A=double(A);
            c=A(C,C);

            LMP_Im(i,j)=255*(u(A(1,2),c,lambda)*P(1,2)+u(A(1,C+1),c,
            lambda)*P(1,C+1)+u(A(R,1),c,lambda)*P(R,1)+u(A(2,L),c,
            lambda)*P(2,L)+u(A(L-1,1),c,lambda)*P(L-1,1)+u(A(C+1,L),c,
            lambda)*P(C+1,L)+u(A(L,R),c,lambda)*P(L,R)+u(A(L,L-1),c,
            lambda)*P(L,L-1))/S;
        end;
    end;
end;

```

```

    LMP_Im = round(LMP_Im);
end

```

## A.3 Rotina para o cálculo do MSLMP3

```

function LMP_Im = MSLMP3(Input_Im, lambda, R)

    if size(Input_Im, 3) == 3
        Input_Im = rgb2gray(Input_Im);
    end;

    R=ceil(R); %% R representa o raio da escala
    L = 2*R+1; %% L=W: tamanho da vizinhanca
    C=round(L/2);
    Input_Im = uint8(Input_Im);
    row_max = size(Input_Im, 1)-L+1;
    col_max = size(Input_Im, 2)-L+1;
    LMP_Im = zeros(row_max, col_max);

    %%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
    P = ones(L,L); %% Define-se a matriz de pesos
    P(C,C) = 0;
    S = 8; %% sum(sum(P));
    %%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

    for i=1:row_max
        for j=1:col_max
            A=Input_Im(i:i+L-1,j:j+L-1);
            A=double(A);
            c=A(C,C);

            resto = rem(R,2);

            if R == 1
                LMP_Im(i,j) = 255*(u(A(1,1), c, lambda)*P(1,1) + u(A(1,C), c,

```

```

        lambda)*P(1,C) + u(A(1,L), c, lambda)*P(1,L) + u(A(C,1), c,
        lambda)*P(C,1) + u(A(C,L), c, lambda)*P(C,L) + u(A(L,1), c,
        lambda)*P(L,1) + u(A(L,C), c, lambda)*P(L,C) + u(A(L,L), c,
        lambda)*P(L,L))/S;

elseif resto == 0
    LMP_Im(i,j) = 255*(u(A(1,1), c, lambda)*P(1,1) + u(A(1,C), c,
    lambda)*P(1,C) + u(A(1,L), c, lambda)*P(1,L) + u(A(C,1), c,
    lambda)*P(C,1) + u(A(C,L), c, lambda)*P(C,L) + u(A(L,1), c,
    lambda)*P(L,1) + u(A(L,C), c, lambda)*P(L,C) + u(A(L,L), c,
    lambda)*P(L,L))/S;

else
    LMP_Im(i,j)=255*(u(A(1,(C/2)+1),c,lambda)*P(1,(C/2)+1)+
    u(A(1,L-(C/2)),c,lambda)*P(1,L-(C/2))+u(A((C/2)+1,1),c,
    lambda)*P((C/2)+1,1)+u(A((C/2)+1,L),c,lambda)*P((C/2)+1,L)+
    u(A(L-(C/2),1),c,lambda)*P(L-(C/2),1)+u(A(L-(C/2),L),c,
    lambda)*P(L-(C/2),L)+u(A(L,(C/2)+1),c,lambda)*P(L,(C/2)+1)+
    u(A(L,L-(C/2)),c,lambda)*P(L,L-(C/2)))/S;
end;
end;
end;

LMP_Im = round(LMP_Im);
end

```

## A.4 Rotina para o cálculo do MSLMP4

```
function LMP_Im = MSLMP4(Input_Im, lambda, R)
```

```

if size(Input_Im, 3) == 3
    Input_Im = rgb2gray(Input_Im);
end;

R=ceil(R); %% R representa o raio da escala

```

```

L = 2*R+1; %% L=W: tamanho da vizinhanca

C=round(L/2);
Input_Im = uint8(Input_Im);
row_max = size(Input_Im, 1)-L+1;
col_max = size(Input_Im, 2)-L+1;
LMP_Im = zeros(row_max, col_max);

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
P = ones(L,L); %% Define-se a matriz de pesos
P(C,C) = 0;
S = 8; %% sum(sum(P));
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

for i=1:row_max
    for j=1:col_max
        A=Input_Im(i:i+L-1,j:j+L-1);
        A=double(A);
        c=A(C,C);

        if R == 1
            LMP_Im(i,j) = 255*(u(A(1,1), c, lambda)*P(1,1) + u(A(1,C), c,
            lambda)*P(1,C) + u(A(1,L), c, lambda)*P(1,L) + u(A(C,1), c,
            lambda)*P(C,1) + u(A(C,L), c, lambda)*P(C,L) + u(A(L,1), c,
            lambda)*P(L,1) + u(A(L,C), c, lambda)*P(L,C) + u(A(L,L), c,
            lambda)*P(L,L))/S;

        else
            LMP_Im(i,j)=255*(u(A(1,2), c, lambda)*P(1,2)+u(A(1,4), c,
            lambda)*P(1,4)+u(A(2,L), c, lambda)*P(2,L)+u(A(L-3,1), c,
            lambda)*P(L-3,1)+u(A(4,L), c, lambda)*P(4,L)+u(A(L-1,1), c,
            lambda)*P(L-1,1)+u(A(L,L-3), c, lambda)*P(L,L-3)+u(A(L,L-1), c,
            lambda)*P(L,L-1))/S;

        end;
    end;
end;

```

```

end;

LMP_Im = round(LMP_Im);
end

```

## A.5 Rotina para o cálculo do MSLMP5

```

function LMP_Im = MSLMP5(Input_Im, lambda, R)

if size(Input_Im, 3) == 3
    Input_Im = rgb2gray(Input_Im);
end;

R=ceil(R); %% R representa o raio da escala
L = 2*R+1; %% L=W: tamanho da vizinhanca
C=round(L/2);
Input_Im = uint8(Input_Im);
row_max = size(Input_Im, 1)-L+1;
col_max = size(Input_Im, 2)-L+1;
LMP_Im = zeros(row_max, col_max);

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
P = ones(L,L); %% Define-se a matriz de pesos
P(C,C) = 0;
S = 8; %% sum(sum(P));
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

for i=1:row_max
    for j=1:col_max
        A=Input_Im(i:i+L-1,j:j+L-1);
        A=double(A);
        c=A(C,C);

        if R == 1
            LMP_Im(i,j) = 255*(u(A(1,1),c,lambda)*P(1,1)+u(A(1,C),c,

```

```

        lambda)*P(1,C)+u(A(1,L),c,lambda)*P(1,L)+u(A(C,1),c,
        lambda)*P(C,1) + u(A(C,L), c, lambda)*P(C,L)+u(A(L,1),c,
        lambda)*P(L,1)+u(A(L,C),c,lambda)*P(L,C)+u(A(L,L),c,
        lambda)*P(L,L))/S;

elseif R==2
    LMP_Im(i,j) = 255*(u(A(1,1),c,lambda)*P(1,1)+u(A(1,C),c,
    lambda)*P(1,C)+u(A(1,L),c,lambda)*P(1,L)+u(A(C,1),c,
    lambda)*P(C,1)+u(A(C,L),c,lambda)*P(C,L)+ u(A(L,1),c,
    lambda)*P(L,1)+u(A(L,C),c,lambda)*P(L,C)+u(A(L,L),c,
    lambda)*P(L,L))/S;

else
    LMP_Im(i,j)=255*(u(A(1,3),c,lambda)*P(1,3)+u(A(1,L-2),c,
    lambda)*P(1,L-2)+u(A(3,1),c,lambda)*P(3,1)+u(A(3,L),c,
    lambda)*P(3,L)+u(A(L-2,1),c,lambda)*P(L-2,1)+u(A(L-2,L),c,
    lambda)*P(L-2,L)+u(A(L,3),c,lambda)*P(L,3)+u(A(L,L-2),c,
    lambda)*P(L,L-2))/S;

end;
end;
end;

LMP_Im = round(LMP_Im);
end

```

## A.6 Rotina para o cálculo do MSLMP6

```

function LMP_Im = MSLMP6(Input_Im, sig, R)

if size(Input_Im, 3) == 3
    Input_Im = rgb2gray(Input_Im);
end;

R = ceil(R);
L = 2*R + 1; %% The size of the LBP matrix
C = round(L/2);

```

```
Input_Im = uint8(Input_Im);
row_max = size(Input_Im,1)-L+1;
col_max = size(Input_Im,2)-L+1;
LBP_Im = zeros(row_max, col_max);

P = ones(L,L); % Matriz de pesos
P(C,C) = 0;

S = sum(sum(P));

for i = 1:row_max
    for j = 1:col_max
        A = Input_Im(i:i+L-1, j:j+L-1);
        A = double(A);
        c = A(C,C);

        acum = 0.0;
        for r = 1:L
            for s=1:L
                acum = acum + u(A(r,s), c, sig)*P(r,s);
            end
        end
        LMP_Im(i,j) = 255*acum/S;
    end;
end;

LMP_Im = round(LMP_Im);
end
```

## APÊNDICE B

### SENSIBILIDADE OBTIDA DO MSLMP COM RESPEITO À MATRIZ DE PESOS 4.11

$S$  (%) para Amostra de tamanho  $45 \times 45$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	37,50	57,50	69,64	79,64	89,38
0,1	42,41	62,41	76,07	82,77	89,64
0,15	50,09	69,82	78,48	84,91	90,63
0,2	54,20	72,32	81,70	86,43	91,16
0,25	56,88	75,45	83,39	88,13	91,79
0,3	61,88	76,96	83,75	88,75	92,05
0,35	65,71	79,46	85,18	89,29	92,05
0,4	67,86	79,11	85,00	88,39	92,14
0,45	68,21	80,89	85,89	89,55	92,41
0,5	69,38	79,20	84,46	89,29	92,86
0,55	71,16	80,80	86,61	90,09	92,59
0,6	70,63	81,70	86,52	89,91	92,86
0,65	73,13	81,43	87,05	90,18	93,48
0,7	73,57	83,04	87,05	90,27	93,21
0,705	73,39	82,77	86,52	90,36	93,21
0,75	73,30	82,50	85,98	90,45	93,04
0,755	72,86	81,96	85,18	90,63	92,95

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,8	73,30	82,95	85,27	89,82	93,21
0,805	73,66	83,84	85,63	89,91	93,57
0,85	72,50	81,34	85,00	90,27	93,30
0,855	72,95	81,16	84,38	89,73	93,13
0,9	72,41	81,70	84,73	89,38	92,86
0,95	75,45	81,96	86,88	90,71	93,48
0,955	75,18	82,23	87,23	90,45	93,39
1	74,20	82,68	87,86	90,18	93,66

$S$  (%) para Amostra de tamanho  $50 \times 50$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	40,36	60,63	77,23	83,39	90,18
0,1	45,89	68,13	80,63	86,34	90,98
0,15	52,68	73,75	83,21	87,86	92,68
0,2	55,89	78,66	85,00	88,21	92,23
0,25	63,30	79,91	87,77	89,46	92,41
0,3	67,32	83,13	88,39	89,46	93,3
0,35	69,64	83,75	88,75	90,18	94,11
0,4	70,18	83,48	89,64	90,00	94,29
0,45	73,21	83,57	89,38	90,45	94,38
0,5	72,50	85,09	89,82	91,07	94,38
0,55	76,70	87,50	90,36	91,25	94,73
0,6	74,82	86,16	90,27	90,98	94,46
0,65	77,86	86,52	90,71	91,70	95,00
0,7	76,07	87,05	90,45	91,52	94,91
0,705	76,34	86,34	90,54	91,34	94,73
0,75	78,93	87,50	89,82	91,88	94,91
0,755	78,21	87,68	89,64	91,52	94,38
0,8	76,43	86,34	90,00	91,61	94,82
0,805	78,57	86,43	89,91	91,70	94,91
0,85	76,70	86,79	89,55	91,34	94,46
0,855	77,86	87,86	89,64	91,43	94,55

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,9	77,32	85,45	89,46	91,16	94,20
0,95	77,86	86,52	89,91	91,88	94,64
0,955	78,04	86,07	89,64	92,14	94,73
1	79,29	87,14	89,73	92,41	94,64

$S$  (%) para Amostra de tamanho  $55 \times 55$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	49,38	68,75	81,70	84,20	90,54
0,1	56,16	73,13	85,09	87,23	90,98
0,15	61,96	81,07	88,04	89,46	92,41
0,2	68,30	83,84	89,02	90,54	92,50
0,25	69,29	86,52	91,43	91,34	92,68
0,3	73,21	84,46	90,00	90,98	93,39
0,35	75,89	87,86	91,34	91,70	93,75
0,4	78,13	87,86	91,61	92,05	93,75
0,45	79,02	87,59	91,34	92,14	94,02
0,5	81,07	87,14	91,52	92,32	94,29
0,55	81,25	89,29	92,41	92,32	94,82
0,6	81,88	87,77	93,21	92,59	94,38
0,65	82,50	89,73	93,30	92,86	94,82
0,7	84,20	90,54	93,39	92,41	95,00
0,705	82,41	90,09	93,57	92,68	95,09
0,75	82,23	89,91	93,57	92,32	94,82
0,755	82,32	89,82	93,66	92,23	94,91
0,8	81,43	89,29	93,04	92,59	95,00
0,805	81,96	89,46	93,30	92,59	94,91
0,85	82,68	89,29	93,30	92,23	94,64
0,855	83,48	89,29	93,30	92,05	94,55
0,9	82,32	88,93	92,59	92,50	94,73
0,95	83,84	89,38	93,13	92,86	95,09
0,955	84,02	89,46	92,77	92,86	95,00
1	83,75	89,46	92,86	92,32	95,18

$S$  (%) para Amostra de tamanho  $60 \times 60$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	56,34	72,14	83,21	89,29	91,61
0,1	62,14	79,02	87,05	90,18	93,04
0,15	68,75	82,32	89,64	92,23	93,84
0,2	73,13	85,80	90,09	92,77	94,11
0,25	75,45	88,13	91,43	94,02	94,11
0,3	79,29	88,93	92,59	93,93	94,20
0,35	80,63	89,20	92,50	93,93	94,46
0,4	82,59	90,80	93,04	94,46	95,45
0,45	82,23	89,11	92,50	93,84	95,45
0,5	82,41	90,00	92,50	94,20	96,07
0,55	85,54	91,43	93,21	94,11	96,25
0,6	85,18	91,52	93,39	94,46	95,89
0,65	86,70	90,63	93,66	94,82	96,16
0,7	86,70	90,63	94,02	94,73	95,80
0,705	88,13	91,07	93,75	94,91	95,80
0,75	86,61	91,25	93,66	94,73	96,07
0,755	85,80	90,98	93,75	94,20	96,07
0,8	84,82	91,96	93,93	94,82	95,71
0,805	85,54	91,61	93,57	94,55	95,98
0,85	84,46	91,43	93,30	94,46	96,07
0,855	84,82	91,25	93,21	94,55	96,07
0,9	85,18	90,54	94,20	94,55	95,71
0,95	86,43	91,61	93,75	94,91	95,80
0,955	85,45	91,79	93,93	94,82	95,71
1	85,09	91,70	93,84	94,46	95,89

$S$  (%) para Amostra de tamanho  $65 \times 65$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	60,00	76,96	87,41	89,20	94,29
0,1	67,14	82,50	89,20	91,52	95,00
0,15	72,95	86,52	91,52	92,77	95,63
0,2	76,79	87,86	91,79	92,86	95,63
0,25	80,00	87,95	93,21	93,04	95,98
0,3	81,16	90,71	93,21	93,75	95,89
0,35	84,91	92,95	94,38	94,11	96,07
0,4	84,64	92,14	94,11	93,84	96,07
0,45	85,71	91,70	93,13	95,27	96,25
0,5	85,71	91,70	93,13	94,46	96,43
0,55	87,23	92,86	94,11	95,36	96,79
0,6	86,52	91,70	94,55	95,09	96,61
0,65	87,59	93,30	94,73	95,00	96,52
0,7	87,86	93,48	94,82	95,18	96,88
0,705	87,68	93,30	94,91	95,63	96,88
0,75	88,84	93,04	95,00	95,09	97,05
0,755	88,39	92,41	94,38	95,27	97,05
0,8	88,48	92,86	94,38	95,45	96,88
0,805	88,04	93,48	94,55	95,36	96,96
0,85	87,86	93,3	94,29	95,36	96,88
0,855	87,68	92,59	94,46	95,18	96,96
0,9	88,66	93,57	94,91	95,36	96,88
0,95	89,38	93,75	95,18	95,00	96,88
0,955	89,20	93,04	94,73	95,27	96,96
1	89,64	93,48	94,91	95,18	96,70

$S$  (%) para Amostra de tamanho  $70 \times 70$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	61,61	81,61	87,86	91,52	95,63
0,1	69,91	86,88	91,52	94,29	95,98
0,15	74,91	88,30	93,30	95,54	96,70
0,2	79,55	90,36	93,57	95,27	96,96
0,25	83,30	91,52	94,55	95,71	97,68
0,3	85,27	92,05	94,11	96,34	97,23
0,35	86,43	93,84	94,73	96,70	97,14
0,4	87,32	94,55	94,29	96,52	97,41
0,45	88,84	93,21	94,38	96,25	97,32
0,5	88,84	93,75	95,18	95,89	97,32
0,55	90,27	93,30	94,46	96,25	97,41
0,6	89,91	93,57	94,11	95,98	97,50
0,65	89,82	93,75	94,02	96,34	97,50
0,7	90,09	94,55	95,18	96,16	97,86
0,705	89,11	94,46	94,91	95,80	97,77
0,75	90,63	94,64	94,91	96,25	97,59
0,755	90,00	94,55	95,00	96,07	97,59
0,8	90,09	94,82	94,02	95,98	97,59
0,805	90,00	94,64	94,20	95,89	97,68
0,85	89,38	94,73	94,91	95,71	97,77
0,855	89,73	94,64	94,91	95,71	97,77
0,9	90,09	95,18	94,20	95,45	97,86
0,95	90,00	95,09	94,38	96,16	97,86
0,955	90,71	94,64	94,64	96,43	97,86
1	90,36	94,91	94,64	96,07	97,95

$S$  (%) para Amostra de tamanho  $75 \times 75$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	71,43	83,66	90,18	93,57	96,52
0,1	75,63	88,13	93,66	94,82	96,61
0,15	78,84	91,16	94,55	95,89	97,23
0,2	82,86	92,23	94,55	96,52	97,77
0,25	84,20	93,66	94,91	97,23	97,41
0,3	89,55	95,36	95,18	96,88	98,04
0,35	89,38	94,64	95,54	97,41	97,95
0,4	90,27	95,18	95,45	97,59	98,48
0,45	89,29	94,91	94,64	97,32	98,66
0,5	89,91	95,98	95,45	97,32	98,84
0,55	91,25	95,80	96,43	97,50	98,93
0,6	91,25	95,80	95,89	97,77	98,48
0,65	92,50	95,27	96,43	98,04	98,48
0,7	91,96	95,45	96,88	97,95	98,75
0,705	92,32	95,18	96,88	98,04	98,66
0,75	92,41	95,89	96,79	97,86	98,75
0,755	92,77	95,71	96,79	97,86	98,57
0,8	92,59	95,80	96,61	97,50	98,57
0,805	92,14	95,54	96,70	97,77	98,57
0,85	92,95	95,45	96,34	97,95	98,66
0,855	92,23	95,09	96,16	97,59	98,66
0,9	92,86	95,18	96,70	97,41	98,66
0,95	92,86	95,45	96,96	97,77	98,57
0,955	92,23	95,27	97,05	97,59	98,75
1	92,14	95,54	96,96	97,59	98,57

$S$  (%) para Amostra de tamanho  $80 \times 80$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	74,82	85,89	91,96	94,91	96,34
0,1	80,80	90,00	94,38	95,98	97,14
0,15	85,09	92,59	95,27	96,70	97,50
0,2	86,52	93,84	96,07	96,79	97,50
0,25	88,75	95,00	95,98	96,96	97,32
0,3	91,16	95,45	96,52	97,23	97,59
0,35	91,61	95,89	96,52	97,05	98,04
0,4	93,04	95,54	96,07	97,05	97,95
0,45	92,32	96,52	96,61	97,32	98,04
0,5	92,86	96,34	96,52	96,96	97,95
0,55	94,73	96,07	96,34	97,95	97,68
0,6	93,84	95,71	95,80	97,59	98,30
0,65	94,46	95,45	96,88	97,77	98,21
0,7	95,18	96,07	96,61	97,77	98,21
0,705	94,73	95,80	96,70	97,68	98,13
0,75	94,82	95,98	97,14	97,95	98,04
0,755	94,82	95,98	97,05	97,95	98,04
0,8	94,11	95,98	96,79	97,86	98,04
0,805	93,84	95,80	96,70	97,95	98,13
0,85	94,82	95,89	96,52	97,77	97,41
0,855	94,64	95,89	96,43	97,77	97,50
0,9	94,38	95,98	96,61	97,68	97,59
0,95	94,82	96,07	96,43	97,59	98,13
0,955	94,73	95,80	96,43	97,68	98,13
1	95,09	96,07	96,43	97,95	98,13

$S$  (%) para Amostra de tamanho  $85 \times 85$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	74,46	88,39	92,68	94,11	96,70
0,1	81,16	92,32	95,18	96,07	97,50
0,15	84,29	93,30	95,71	95,80	97,95
0,2	87,32	94,46	96,16	96,79	97,59
0,25	90,63	95,36	97,05	96,43	97,68
0,3	91,25	95,45	97,05	96,88	97,77
0,35	91,96	96,16	97,23	96,96	98,13
0,4	93,21	96,70	97,50	96,70	98,21
0,45	93,66	96,34	96,96	97,05	98,21
0,5	92,95	95,98	97,50	97,23	98,13
0,55	94,82	96,96	97,14	97,05	98,39
0,6	94,38	96,70	97,59	97,05	98,48
0,65	94,02	96,61	97,50	97,32	98,48
0,7	94,64	96,25	97,50	97,14	98,48
0,705	94,82	96,52	97,41	97,32	98,39
0,75	94,46	96,70	97,50	97,05	98,30
0,755	94,82	96,79	97,14	97,05	98,39
0,8	93,13	96,25	97,59	97,50	98,39
0,805	93,21	96,25	97,50	97,50	98,21
0,85	93,93	96,61	97,32	97,41	98,30
0,855	93,84	96,61	97,50	97,50	98,21
0,9	94,38	96,70	97,50	97,41	97,86
0,95	95,18	96,61	97,68	97,68	98,30
0,955	94,91	96,88	97,59	97,86	98,30
1	95,54	96,43	97,59	97,86	98,13

$S$  (%) para Amostra de tamanho  $90 \times 90$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	79,55	90,18	93,93	94,73	96,79
0,1	84,55	93,66	95,63	96,25	97,14
0,15	87,95	94,38	96,16	97,05	97,68
0,2	90,36	95,63	97,41	97,86	97,50
0,25	91,88	96,88	97,14	97,68	97,77
0,3	92,05	97,05	97,50	97,77	97,86
0,35	93,66	96,88	97,68	98,13	98,13
0,4	93,75	96,52	97,41	97,95	97,95
0,45	93,93	97,41	97,32	97,95	97,77
0,5	94,20	96,96	97,23	97,68	97,95
0,55	95,54	97,23	97,23	98,13	98,21
0,6	95,98	97,05	97,32	98,30	98,13
0,65	95,36	97,41	97,50	98,21	98,13
0,7	95,27	97,41	97,41	98,04	98,39
0,705	95,18	97,59	97,59	98,13	98,39
0,75	95,63	97,14	97,32	98,04	98,13
0,755	96,25	97,41	97,59	98,13	98,13
0,8	95,36	97,32	97,50	98,04	98,30
0,805	95,18	97,23	97,68	98,13	98,30
0,85	95,27	97,32	97,41	98,30	98,21
0,855	95,18	97,23	97,41	98,21	98,21
0,9	95,89	96,52	97,50	98,04	98,21
0,95	95,45	97,14	97,14	97,86	98,13
0,955	95,18	97,05	97,32	98,04	98,04
1	95,89	96,88	97,50	97,95	98,04

## APÊNDICE C

### SENSIBILIDADE OBTIDA DO MSLMP COM RESPEITO À MATRIZ DE PESOS 4.12

$S$  (%) para Amostra de tamanho  $45 \times 45$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	37,59	57,50	69,20	78,75	88,57
0,1	42,41	62,41	72,86	82,05	89,29
0,15	50,36	69,73	75,98	85,63	89,91
0,2	54,20	72,32	81,43	87,41	90,45
0,25	56,96	75,45	81,96	87,77	91,61
0,3	62,05	76,96	84,29	87,59	92,86
0,35	65,80	79,46	85,09	88,21	92,77
0,4	67,95	79,11	84,11	88,66	92,77
0,45	68,21	80,89	84,38	88,66	92,68
0,5	69,29	79,20	85,63	90,18	93,30
0,55	71,07	80,80	86,16	89,11	92,95
0,6	70,54	81,70	85,63	88,93	93,39
0,65	73,13	81,43	86,79	89,38	93,66
0,7	73,57	83,04	85,80	89,73	93,75
0,705	73,39	82,77	86,07	89,46	93,75
0,75	73,30	82,50	86,52	89,46	93,66
0,755	72,86	81,96	86,43	88,75	93,66

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,8	73,30	82,95	85,54	88,57	93,39
0,805	73,75	83,84	85,54	88,84	93,04
0,85	72,50	81,34	85,45	89,73	93,48
0,855	72,95	81,16	85,71	89,29	93,30
0,9	72,50	81,70	85,18	88,93	93,66
0,95	75,36	81,96	86,16	90,00	93,57
0,955	75,27	82,23	85,98	89,91	93,57
1	74,11	82,68	86,79	90,00	93,48

$S$  (%) para Amostra de tamanho  $50 \times 50$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	40,27	60,63	76,34	81,61	89,38
0,1	45,89	68,13	78,21	85,09	90,71
0,15	52,68	73,84	83,13	86,79	91,25
0,2	55,89	78,57	84,46	87,59	92,05
0,25	63,30	79,91	86,96	89,11	92,59
0,3	67,23	83,13	87,32	88,84	93,39
0,35	69,55	83,75	88,30	89,11	93,13
0,4	70,18	83,48	89,29	90,27	93,75
0,45	73,21	83,57	88,13	90,36	94,55
0,5	72,50	85,00	88,13	89,46	93,57
0,55	76,70	87,50	89,55	90,63	94,38
0,6	74,82	86,16	89,73	90,18	94,82
0,65	77,77	86,52	89,38	91,79	94,46
0,7	76,07	87,05	89,11	91,16	95,00
0,705	76,34	86,34	89,29	91,34	94,82
0,75	78,93	87,50	89,46	91,43	94,29
0,755	78,21	87,68	89,02	91,16	94,38
0,8	76,43	86,34	88,84	91,43	94,55
0,805	78,66	86,43	88,93	90,89	94,64
0,85	76,79	86,70	89,11	90,89	94,46
0,855	77,86	87,86	89,38	91,16	94,55

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,9	77,41	85,54	88,13	91,07	94,20
0,95	77,77	86,43	89,64	91,70	94,64
0,955	78,13	86,07	89,55	91,61	94,64
1	79,29	87,14	90,18	91,96	95,09

$S$  (%) para Amostra de tamanho  $55 \times 55$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	49,55	68,75	80,00	85,36	90,54
0,1	56,16	73,21	83,75	87,50	91,79
0,15	62,05	81,07	88,04	90,54	92,95
0,2	68,13	83,84	90,36	90,27	92,50
0,25	69,38	86,52	90,98	91,34	93,30
0,3	73,21	84,46	91,16	90,36	93,39
0,35	75,80	87,86	91,52	92,41	93,21
0,4	78,13	87,86	91,07	91,25	93,75
0,45	79,02	87,59	91,61	91,96	94,29
0,5	81,07	87,14	92,32	92,77	94,11
0,55	81,34	89,29	92,50	92,86	94,73
0,6	81,79	87,77	93,30	92,77	94,55
0,65	82,41	89,73	93,93	93,21	95,09
0,7	84,20	90,54	93,04	93,30	95,18
0,705	82,41	90,09	93,57	93,13	95,18
0,75	82,23	89,91	93,13	92,68	95,00
0,755	82,32	89,82	93,04	92,68	94,91
0,8	81,43	89,29	93,30	93,13	95,00
0,805	81,96	89,46	93,39	93,21	94,64
0,85	82,77	89,29	93,57	93,13	94,55
0,855	83,48	89,29	93,66	93,13	94,46
0,9	82,23	88,93	92,68	93,13	94,46
0,95	83,84	89,38	92,95	94,02	94,91
0,955	84,11	89,38	93,21	93,84	95,00
1	83,75	89,46	92,86	94,02	94,82

$S$  (%) para Amostra de tamanho  $60 \times 60$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	56,25	72,14	81,70	87,68	91,25
0,1	62,23	79,02	87,32	91,16	92,32
0,15	68,75	82,41	89,02	92,68	93,39
0,2	73,13	85,89	90,45	92,59	93,21
0,25	75,45	88,13	90,63	93,21	93,75
0,3	79,29	88,93	92,68	93,39	93,84
0,35	80,54	89,20	92,86	94,20	94,91
0,4	82,68	90,80	92,41	94,20	95,54
0,45	82,23	89,11	91,88	93,93	95,45
0,5	82,32	90,00	91,61	94,38	95,80
0,55	85,36	91,34	93,21	94,46	96,07
0,6	85,18	91,52	92,32	94,11	95,63
0,65	86,70	90,63	93,04	94,55	95,98
0,7	86,70	90,63	93,66	93,93	96,16
0,705	88,13	91,07	93,48	94,38	95,98
0,75	86,61	91,25	93,48	94,20	96,61
0,755	85,80	90,98	93,30	94,29	96,61
0,8	84,82	91,96	93,04	94,11	96,25
0,805	85,45	91,61	93,13	94,20	95,98
0,85	84,29	91,43	93,13	94,38	95,98
0,855	84,73	91,25	93,04	94,20	95,89
0,9	85,18	90,54	93,13	94,38	95,89
0,95	86,43	91,61	93,57	94,29	96,07
0,955	85,36	91,79	93,57	94,02	96,25
1	84,91	91,70	93,75	94,20	96,16

$S$  (%) para Amostra de tamanho  $65 \times 65$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	59,82	76,96	84,38	89,38	94,91
0,1	67,14	82,50	87,77	91,43	95,09
0,15	73,13	86,52	90,80	93,13	95,36
0,2	76,96	87,86	92,32	93,21	95,71
0,25	79,91	87,95	92,05	93,84	96,34
0,3	81,16	90,71	92,50	94,11	96,25
0,35	84,91	92,95	93,04	94,46	96,88
0,4	84,64	92,14	93,48	94,29	96,79
0,45	85,71	91,70	93,39	94,38	96,79
0,5	85,71	91,70	94,02	94,82	96,96
0,55	87,14	92,86	94,73	95,36	96,96
0,6	86,52	91,70	94,73	95,54	97,14
0,65	87,50	93,30	95,18	95,18	96,79
0,7	87,86	93,48	94,55	95,80	96,96
0,705	87,68	93,30	94,55	95,63	97,14
0,75	88,84	93,04	95,09	95,89	96,96
0,755	88,39	92,41	94,82	95,80	96,88
0,8	88,48	92,86	94,82	95,54	97,05
0,805	88,04	93,48	94,64	95,45	97,23
0,85	87,77	93,30	94,73	95,63	96,70
0,855	87,68	92,59	94,73	95,54	96,61
0,9	88,66	93,48	94,82	95,45	96,79
0,95	89,29	93,75	94,73	95,89	96,96
0,955	89,20	93,04	94,55	95,71	96,96
1	89,64	93,48	95,45	95,80	96,79

$S$  (%) para Amostra de tamanho  $70 \times 70$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	61,25	81,61	86,43	92,05	95,80
0,1	69,91	86,88	90,71	94,73	96,43
0,15	75,00	88,30	92,95	96,43	96,61
0,2	79,64	90,36	94,11	96,07	96,70
0,25	83,39	91,52	94,46	95,80	97,05
0,3	85,27	92,05	94,82	96,07	97,23
0,35	86,43	93,84	94,20	96,16	97,41
0,4	87,32	94,55	94,55	96,07	97,41
0,45	88,84	93,21	94,82	96,43	97,41
0,5	88,75	93,75	95,18	96,07	97,50
0,55	90,27	93,30	94,91	96,52	97,68
0,6	89,91	93,57	94,91	96,43	97,68
0,65	89,82	93,75	94,64	96,16	97,95
0,7	90,09	94,55	94,91	96,61	98,04
0,705	89,11	94,46	95,09	96,34	97,95
0,75	90,63	94,64	94,91	96,25	97,95
0,755	90,00	94,55	94,82	95,89	97,95
0,8	90,09	94,82	94,64	95,63	97,95
0,805	90,00	94,64	94,64	95,71	97,95
0,85	89,46	94,73	94,82	95,89	97,86
0,855	89,64	94,64	94,73	95,89	97,86
0,9	90,09	95,18	94,55	95,45	97,95
0,95	89,82	95,09	94,64	96,25	97,95
0,955	90,71	94,64	94,55	96,25	97,95
1	90,27	94,91	94,73	96,16	97,95

$S$  (%) para Amostra de tamanho  $75 \times 75$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	71,43	83,66	89,46	93,75	95,63
0,1	75,63	88,13	91,96	94,55	96,88
0,15	78,84	91,16	93,84	95,45	97,05
0,2	82,95	92,23	94,11	96,96	97,41
0,25	84,20	93,66	94,91	96,79	97,59
0,3	89,64	95,36	94,91	97,41	98,04
0,35	89,38	94,55	95,63	97,41	97,86
0,4	90,27	95,18	95,00	97,59	98,30
0,45	89,29	94,91	94,64	97,86	98,13
0,5	90,00	95,98	94,82	97,77	98,39
0,55	91,25	95,80	95,89	97,86	98,48
0,6	91,25	95,80	96,25	97,77	98,13
0,65	92,50	95,27	96,07	98,04	98,75
0,7	91,96	95,45	96,61	98,21	98,66
0,705	92,32	95,18	96,34	98,30	98,66
0,75	92,41	95,89	96,88	98,39	98,21
0,755	92,77	95,71	96,70	98,39	98,21
0,8	92,59	95,80	96,52	98,04	98,39
0,805	92,23	95,54	95,98	98,21	98,39
0,85	92,86	95,45	96,16	97,77	98,39
0,855	92,23	95,09	96,07	97,77	98,30
0,9	92,77	95,18	96,52	97,77	98,39
0,95	92,86	95,45	96,79	98,04	98,66
0,955	92,23	95,27	96,70	97,95	98,75
1	92,14	95,54	96,79	97,77	98,57

$S$  (%) para Amostra de tamanho  $80 \times 80$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	74,82	85,89	90,98	93,93	95,71
0,1	80,89	90,18	93,39	95,80	96,79
0,15	85,18	92,59	95,00	96,96	96,96
0,2	86,52	93,84	95,18	97,23	97,32
0,25	88,66	95,00	96,52	96,70	97,69
0,3	91,16	95,45	96,70	97,14	97,68
0,35	91,61	95,89	96,43	97,32	98,04
0,4	93,04	95,54	95,80	97,14	98,13
0,45	92,14	96,43	96,52	97,23	98,04
0,5	92,86	96,34	96,16	97,23	97,86
0,55	94,82	96,07	96,25	97,50	98,13
0,6	93,84	95,71	96,25	97,23	98,48
0,65	94,46	95,45	96,96	97,59	98,39
0,7	95,18	96,07	96,61	97,68	98,13
0,705	94,73	95,80	96,52	97,77	98,13
0,75	94,82	95,98	96,52	97,41	98,39
0,755	94,82	95,98	96,25	97,41	98,39
0,8	94,11	95,98	96,88	97,32	98,30
0,805	93,84	95,80	96,79	97,68	98,39
0,85	94,82	95,89	96,52	97,32	98,04
0,855	94,64	95,89	96,61	97,23	98,04
0,9	94,38	96,07	96,61	97,14	97,86
0,95	94,82	96,07	96,70	97,23	98,04
0,955	94,64	95,80	96,70	97,23	98,21
1	95,09	96,07	96,61	97,41	98,21

$S$  (%) para Amostra de tamanho  $85 \times 85$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	74,46	88,39	92,50	93,48	96,25
0,1	81,16	92,32	94,64	96,52	97,41
0,15	84,29	93,30	95,36	96,43	97,77
0,2	87,32	94,46	96,34	96,52	97,68
0,25	90,63	95,36	96,61	97,23	97,86
0,3	91,43	95,54	97,32	96,88	97,77
0,35	91,96	96,07	97,68	96,96	98,21
0,4	93,30	96,70	97,41	97,32	98,30
0,45	93,66	96,34	97,05	97,14	98,13
0,5	92,86	95,98	97,23	97,41	97,95
0,55	94,82	96,96	97,32	97,23	98,48
0,6	94,38	96,70	97,32	97,14	98,84
0,65	94,02	96,70	97,41	97,50	98,75
0,7	94,64	96,25	97,32	97,86	98,66
0,705	94,82	96,52	97,41	97,68	98,66
0,75	94,46	96,70	97,05	97,68	98,66
0,755	94,82	96,79	97,23	97,77	98,66
0,8	93,13	96,25	97,23	97,41	98,57
0,805	93,30	96,25	97,50	97,50	98,57
0,85	93,93	96,61	97,50	97,50	98,39
0,855	93,84	96,61	97,50	97,68	98,39
0,9	94,38	96,70	97,41	97,32	98,48
0,95	95,18	96,61	97,05	97,68	98,48
0,955	94,91	96,88	97,05	97,68	98,48
1	95,54	96,43	97,23	97,59	98,39

$S$  (%) para Amostra de tamanho  $90 \times 90$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	79,73	90,18	92,59	94,55	96,34
0,1	84,55	93,66	95,98	96,16	97,32
0,15	88,04	94,38	96,61	96,88	97,32
0,2	90,45	95,63	96,79	97,50	97,77
0,25	91,88	96,88	97,14	97,50	97,77
0,3	91,96	97,05	97,59	97,86	97,68
0,35	93,66	96,88	98,04	97,95	98,21
0,4	93,75	96,52	97,23	97,95	98,04
0,45	93,93	97,41	97,32	98,04	98,13
0,5	94,20	96,96	97,23	98,21	97,95
0,55	95,54	97,23	97,59	98,04	98,04
0,6	95,98	97,05	97,59	98,04	98,04
0,65	95,36	97,41	97,68	98,30	98,30
0,7	95,27	97,41	97,50	98,21	98,30
0,705	95,18	97,59	97,68	98,30	98,30
0,75	95,63	97,14	97,41	97,95	98,39
0,755	96,25	97,41	97,50	97,95	98,39
0,8	95,36	97,32	97,68	98,21	98,13
0,805	95,18	97,23	97,59	98,30	98,21
0,85	95,27	97,23	97,68	98,21	98,21
0,855	95,18	97,23	97,32	98,21	98,21
0,9	95,89	96,52	97,59	97,95	98,04
0,95	95,45	97,14	97,32	98,30	97,95
0,955	95,18	97,05	97,32	98,30	98,04
1	95,89	96,88	97,05	98,21	97,95

## APÊNDICE D

### SENSIBILIDADE OBTIDA DO MSLMP COM RESPEITO À MATRIZ DE PESOS 4.13

$S$  (%) para Amostra de tamanho  $45 \times 45$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	37,50	57,32	70,18	79,82	87,14
0,1	42,41	63,57	73,57	82,77	87,59
0,15	50,09	67,32	78,39	85,54	88,48
0,2	54,20	70,27	80,89	86,52	89,29
0,25	56,88	74,64	81,61	88,04	90,89
0,3	61,88	76,16	83,21	87,77	91,16
0,35	65,71	79,20	82,95	88,93	91,43
0,4	67,86	78,13	82,59	88,84	91,16
0,45	68,21	80,45	84,11	89,38	91,79
0,5	69,38	80,00	84,29	89,20	91,70
0,55	71,16	79,82	85,36	89,64	92,23
0,6	70,63	78,66	84,82	88,93	92,41
0,65	73,13	79,82	85,18	90,80	92,50
0,7	73,57	81,25	84,46	89,64	92,14
0,705	73,39	81,61	84,46	89,91	92,23
0,75	73,30	79,82	84,29	89,91	92,41
0,755	72,86	79,91	84,29	89,38	91,88

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,8	73,30	80,18	83,75	89,73	91,88
0,805	73,66	81,16	84,02	90,00	92,14
0,85	72,50	80,45	84,20	89,73	91,34
0,855	72,95	80,89	84,46	89,91	91,43
0,9	72,41	80,89	84,02	89,29	91,52
0,95	75,45	80,00	84,91	90,18	92,50
0,955	75,18	79,73	85,00	90,27	92,32
1	74,20	81,88	85,54	89,73	92,50

$S$  (%) para Amostra de tamanho  $50 \times 50$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	40,36	62,23	75,63	82,50	89,20
0,1	45,89	66,79	80,36	84,91	89,11
0,15	52,68	73,39	83,75	86,43	90,63
0,2	55,89	77,23	85,18	88,48	91,34
0,25	63,30	79,73	86,52	88,75	91,79
0,3	67,32	82,95	87,41	89,91	92,50
0,35	69,64	83,84	87,32	90,09	93,13
0,4	70,18	83,21	88,30	89,29	93,48
0,45	73,21	83,57	88,48	90,98	93,57
0,5	72,50	84,82	88,93	90,09	93,66
0,55	76,70	86,16	89,73	91,25	94,11
0,6	74,82	86,88	88,84	90,45	94,02
0,65	77,86	86,34	89,91	91,96	93,75
0,7	76,07	86,61	89,64	91,52	94,38
0,705	76,34	87,14	89,46	91,61	94,38
0,75	78,93	87,59	89,73	91,61	94,11
0,755	78,21	87,05	90,00	91,88	93,93
0,8	76,43	86,52	89,11	91,96	93,66
0,805	78,57	86,61	89,11	91,52	93,75
0,85	76,70	86,61	88,84	90,80	93,75
0,855	77,86	87,23	88,57	90,45	93,66

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,9	77,32	86,43	88,21	91,52	93,93
0,95	77,86	85,63	88,48	92,14	94,46
0,955	78,04	85,98	88,57	92,23	94,55
1	79,29	86,88	88,04	92,68	94,55

$S$  (%) para Amostra de tamanho  $55 \times 55$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	49,38	68,30	79,82	85,54	89,11
0,1	56,16	73,75	84,29	88,21	90,89
0,15	61,96	80,45	87,86	89,82	92,41
0,2	68,30	81,79	89,29	90,63	92,14
0,25	69,29	84,29	90,98	90,89	92,32
0,3	73,21	86,52	91,61	91,70	92,95
0,35	75,89	85,98	91,34	91,96	93,13
0,4	78,13	86,52	90,80	91,61	93,21
0,45	79,02	87,95	91,25	92,14	93,48
0,5	81,07	86,79	91,16	92,68	93,48
0,55	81,25	89,20	93,21	92,86	94,46
0,6	81,88	88,75	91,96	92,59	94,46
0,65	82,50	89,29	92,86	92,86	94,20
0,7	84,20	89,46	92,41	92,86	94,64
0,705	82,41	89,38	92,86	92,86	94,64
0,75	82,23	88,84	92,14	92,77	94,82
0,755	82,32	88,66	92,05	92,95	94,73
0,8	81,43	87,77	92,05	91,70	94,55
0,805	81,96	88,48	92,14	91,88	94,55
0,85	82,68	88,30	92,32	92,86	93,93
0,855	83,48	88,39	92,59	92,68	94,20
0,9	82,32	88,93	91,88	92,41	94,20
0,95	83,84	88,21	92,05	92,68	94,73
0,955	84,02	88,57	91,88	92,50	94,82
1	83,75	87,50	92,23	92,50	95,18

$S$  (%) para Amostra de tamanho  $60 \times 60$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	56,34	73,75	82,14	87,68	90,89
0,1	62,14	78,39	85,80	90,36	91,96
0,15	68,75	83,21	88,93	91,34	92,86
0,2	73,13	86,79	89,46	93,21	93,57
0,25	75,45	86,70	91,07	93,04	93,84
0,3	79,29	88,84	91,70	94,29	94,64
0,35	80,63	89,55	91,07	93,93	94,91
0,4	82,59	88,57	92,86	93,57	95,18
0,45	82,23	89,91	92,86	94,29	95,27
0,5	82,41	89,46	92,59	94,02	95,27
0,55	85,54	90,63	93,21	93,93	95,36
0,6	85,18	90,45	93,39	94,02	95,27
0,65	86,70	90,89	93,04	94,73	95,63
0,7	86,70	90,98	93,93	94,55	95,80
0,705	88,13	91,16	93,75	94,38	95,45
0,75	86,61	90,98	94,02	94,29	95,54
0,755	85,80	90,80	94,11	94,38	95,45
0,8	84,82	90,36	93,48	94,20	95,00
0,805	85,54	90,54	93,13	93,66	94,82
0,85	84,46	90,00	93,75	94,11	94,82
0,855	84,82	90,36	93,57	93,93	95,00
0,9	85,18	89,64	93,39	93,66	95,18
0,95	86,43	90,89	93,57	94,02	95,63
0,955	85,45	90,36	93,84	94,11	95,45
1	85,09	89,91	93,93	94,38	95,71

$S$  (%) para Amostra de tamanho  $65 \times 65$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	60,00	77,95	85,18	88,21	94,38
0,1	67,14	83,93	88,66	92,32	94,73
0,15	72,95	85,63	90,71	93,21	95,36
0,2	76,79	87,68	91,79	93,21	95,09
0,25	80,00	88,30	91,79	94,29	95,71
0,3	81,16	90,27	92,95	93,84	96,25
0,35	84,91	91,61	93,39	94,02	95,80
0,4	84,64	92,50	93,39	93,66	95,80
0,45	85,71	91,52	92,95	93,93	96,16
0,5	85,71	91,16	93,04	94,38	96,61
0,55	87,23	92,05	94,38	95,45	96,52
0,6	86,52	91,70	93,48	94,91	96,34
0,65	87,59	93,21	94,38	94,91	96,88
0,7	87,86	93,04	94,29	95,27	97,05
0,705	87,68	92,77	94,11	95,36	96,96
0,75	88,84	92,77	93,75	95,80	96,79
0,755	88,39	92,14	94,20	95,63	96,79
0,8	88,48	93,13	93,66	95,63	96,52
0,805	88,04	92,68	93,75	95,71	96,61
0,85	87,86	92,41	94,38	95,45	96,61
0,855	87,68	92,50	94,20	95,45	96,61
0,9	88,66	92,95	94,38	95,27	96,52
0,95	89,38	92,95	94,73	95,71	96,96
0,955	89,20	92,86	94,73	95,71	97,05
1	89,64	92,77	94,73	95,71	96,52

$S$  (%) para Amostra de tamanho  $70 \times 70$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	61,61	82,41	85,54	92,50	95,36
0,1	69,91	84,38	91,52	94,73	95,36
0,15	74,91	89,20	92,86	95,98	95,09
0,2	79,55	89,02	93,66	95,36	95,98
0,25	83,30	91,43	93,48	96,43	96,25
0,3	85,27	91,61	94,02	95,98	96,25
0,35	86,43	92,77	94,11	96,34	96,79
0,4	87,32	93,48	94,55	96,70	96,96
0,45	88,84	91,61	94,29	96,43	97,05
0,5	88,84	93,21	94,55	96,34	97,50
0,55	90,27	93,48	94,64	96,88	96,88
0,6	89,91	93,57	94,64	96,34	97,05
0,65	89,82	94,64	95,00	96,34	97,59
0,7	90,09	94,82	94,82	95,98	97,59
0,705	89,11	95,00	94,64	95,98	97,50
0,75	90,63	94,20	94,55	95,80	97,59
0,755	90,00	94,29	94,11	95,71	97,59
0,8	90,09	94,11	93,48	95,00	97,50
0,805	90,00	94,73	93,93	95,00	97,50
0,85	89,38	94,38	94,29	95,71	97,41
0,855	89,73	94,46	94,11	95,36	97,50
0,9	90,09	94,55	94,20	94,91	97,32
0,95	90,00	94,82	94,64	95,98	97,68
0,955	90,71	94,64	94,20	96,07	97,68
1	90,36	94,64	94,64	95,89	97,86

$S$  (%) para Amostra de tamanho  $75 \times 75$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	71,43	83,75	88,13	93,39	96,07
0,1	75,63	88,13	91,79	94,91	96,34
0,15	78,84	91,07	92,68	95,63	96,88
0,2	82,86	92,77	93,75	96,70	96,96
0,25	84,20	94,02	94,91	96,70	97,68
0,3	89,55	95,36	95,00	96,88	97,41
0,35	89,38	94,73	95,45	97,41	97,77
0,4	90,27	95,27	95,80	97,32	98,30
0,45	89,29	95,63	95,00	97,50	98,13
0,5	89,91	95,71	95,71	97,50	98,57
0,55	91,25	96,34	96,79	97,68	98,30
0,6	91,25	95,71	96,34	97,77	98,66
0,65	92,50	95,80	96,07	98,04	98,66
0,7	91,96	95,54	96,88	98,13	98,75
0,705	92,32	95,54	96,88	98,04	98,66
0,75	92,41	95,63	96,43	97,86	98,30
0,755	92,77	96,25	96,34	97,95	98,30
0,8	92,59	95,45	96,43	98,04	98,39
0,805	92,14	95,36	96,43	98,13	98,39
0,85	92,95	95,63	96,16	98,04	98,21
0,855	92,23	95,27	95,89	97,95	98,13
0,9	92,86	95,45	96,43	97,77	98,21
0,95	92,86	95,63	96,88	98,13	98,39
0,955	92,23	95,54	96,88	98,13	98,57
1	92,14	95,54	96,61	97,86	98,30

$S$  (%) para Amostra de tamanho  $80 \times 80$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	74,82	86,16	91,43	93,66	95,89
0,1	80,80	90,27	93,93	95,36	96,70
0,15	85,09	92,32	94,55	96,52	97,05
0,2	86,52	93,66	95,71	96,96	97,05
0,25	88,75	94,55	96,25	96,70	97,59
0,3	91,16	94,46	96,61	97,32	97,41
0,35	91,61	95,27	96,79	97,32	97,41
0,4	93,04	95,54	96,43	97,41	97,50
0,45	92,32	95,80	95,98	97,59	97,77
0,5	92,86	95,89	95,98	97,14	97,68
0,55	94,73	96,16	96,52	97,50	97,68
0,6	93,84	95,36	96,52	96,88	97,77
0,65	94,46	95,89	96,70	97,05	98,30
0,7	95,18	95,80	96,79	97,23	97,95
0,705	94,73	95,98	96,88	97,59	98,13
0,75	94,82	95,89	96,52	97,32	97,68
0,755	94,82	95,71	96,70	97,23	97,50
0,8	94,11	95,80	96,52	97,59	97,86
0,805	93,84	96,07	96,79	97,50	97,95
0,85	94,82	96,07	96,88	97,05	97,77
0,855	94,64	96,07	97,14	97,14	97,68
0,9	94,38	96,16	96,52	97,14	97,77
0,95	94,82	96,43	96,79	97,14	98,04
0,955	94,73	96,34	96,79	97,41	98,13
1	95,09	96,34	96,43	97,23	98,30

$S$  (%) para Amostra de tamanho  $85 \times 85$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	74,46	87,59	92,23	94,11	96,43
0,1	81,16	92,68	95,18	95,71	97,41
0,15	84,29	93,39	94,64	95,98	97,23
0,2	87,32	94,82	95,98	96,34	97,59
0,25	90,63	95,27	97,05	96,88	97,59
0,3	91,25	95,98	96,88	96,43	97,86
0,35	91,96	95,54	97,23	96,43	98,04
0,4	93,21	96,16	97,23	96,61	97,95
0,45	93,66	96,07	96,79	97,05	98,13
0,5	92,95	95,80	96,96	97,05	98,04
0,55	94,82	96,43	97,41	97,05	98,30
0,6	94,38	96,16	97,14	96,96	98,66
0,65	94,02	97,14	97,23	97,50	98,66
0,7	94,64	96,07	97,32	97,86	98,57
0,705	94,82	96,07	97,50	97,77	98,66
0,75	94,46	96,61	97,50	97,77	98,39
0,755	94,82	96,34	97,50	97,68	98,21
0,8	93,13	96,25	97,23	97,68	98,30
0,805	93,21	96,25	97,23	97,86	98,39
0,85	93,93	96,25	97,32	97,68	98,04
0,855	93,84	96,61	97,41	97,50	98,04
0,9	94,38	96,25	97,32	97,95	98,04
0,95	95,18	96,70	97,32	98,13	98,48
0,955	94,91	96,79	97,23	97,95	98,57
1	95,54	95,98	97,05	98,13	98,30

$S$  (%) para Amostra de tamanho  $90 \times 90$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	79,55	91,88	92,95	94,20	96,25
0,1	84,55	93,39	95,89	96,43	96,61
0,15	87,95	94,64	96,34	96,96	97,32
0,2	90,36	95,18	97,32	97,23	97,86
0,25	91,88	96,16	97,14	97,14	97,68
0,3	92,05	96,88	97,41	97,32	97,86
0,35	93,66	97,32	97,68	97,77	97,50
0,4	93,75	96,96	97,14	97,77	98,30
0,45	93,93	97,05	97,23	97,68	98,04
0,5	94,20	97,05	97,50	97,86	98,21
0,55	95,54	97,59	97,23	97,77	98,04
0,6	95,98	97,41	97,68	97,95	98,13
0,65	95,36	97,77	97,77	98,21	98,39
0,7	95,27	97,59	97,41	97,86	98,39
0,705	95,18	97,50	97,41	97,95	98,39
0,75	95,63	97,32	97,23	97,77	98,57
0,755	96,25	96,88	97,41	97,77	98,48
0,8	95,36	96,61	97,41	97,77	98,30
0,805	95,18	96,70	97,50	97,77	98,39
0,85	95,27	97,23	97,32	97,77	98,13
0,855	95,18	96,88	97,14	97,59	98,30
0,9	95,89	96,52	97,32	97,77	98,21
0,95	95,45	96,61	97,14	98,04	98,21
0,955	95,18	96,70	97,23	98,13	98,21
1	95,89	96,52	97,05	98,21	98,30

## APÊNDICE E

### SENSIBILIDADE OBTIDA DO MSLMP COM RESPEITO À MATRIZ DE PESOS 4.14

$S$  (%) para Amostra de tamanho  $45 \times 45$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	37,50	57,50	68,93	79,11	87,50
0,1	42,41	62,41	74,91	81,43	88,48
0,15	50,09	69,82	77,86	83,75	89,29
0,2	54,20	72,32	79,46	84,29	89,91
0,25	56,88	75,45	82,50	85,00	91,25
0,3	61,88	76,96	83,84	84,91	91,25
0,35	65,71	79,46	83,75	86,70	91,34
0,4	67,86	79,11	83,84	86,79	91,61
0,45	68,21	80,89	84,55	86,34	91,88
0,5	69,38	79,20	85,36	87,05	92,41
0,55	71,16	80,71	84,91	87,86	92,50
0,6	70,63	81,70	85,63	87,59	92,68
0,65	73,13	81,52	86,25	87,50	92,95
0,7	73,57	83,04	84,64	88,39	92,77
0,705	73,39	82,77	85,00	88,30	92,41
0,75	73,30	82,50	85,45	89,38	92,41
0,755	72,86	81,96	84,38	88,75	92,05

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,8	73,30	82,95	84,55	88,13	92,32
0,805	73,66	83,84	84,11	88,21	92,23
0,85	72,50	81,34	83,84	88,75	91,96
0,855	72,95	81,16	84,02	88,93	91,88
0,9	72,41	81,70	83,21	87,95	92,05
0,95	75,45	81,96	85,80	88,66	92,50
0,955	75,18	82,23	86,07	88,93	92,68
1	74,20	82,68	85,89	88,84	92,59

$S$  (%) para Amostra de tamanho  $50 \times 50$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	40,36	60,54	74,64	81,25	87,41
0,1	45,89	68,13	77,32	83,93	88,30
0,15	52,68	73,75	82,14	86,70	89,29
0,2	55,89	78,57	84,38	86,96	89,91
0,25	63,30	79,91	85,98	88,75	90,45
0,3	67,32	83,13	85,80	88,13	91,34
0,35	69,64	83,75	87,68	89,20	91,34
0,4	70,18	83,48	88,13	88,84	92,32
0,45	73,21	83,57	87,05	89,11	92,50
0,5	72,50	85,09	87,05	89,82	93,04
0,55	76,70	87,50	89,02	90,00	93,66
0,6	74,82	86,16	88,30	90,54	93,48
0,65	77,86	86,52	89,46	91,43	93,75
0,7	76,07	87,05	88,93	91,34	93,66
0,705	76,34	86,34	89,29	91,52	93,66
0,75	78,93	87,50	89,02	91,79	93,75
0,755	78,21	87,68	89,20	91,70	93,48
0,8	76,43	86,34	89,29	91,61	93,75
0,805	78,57	86,43	89,02	91,88	93,75
0,85	76,70	86,79	89,64	91,52	93,84
0,855	77,86	87,86	88,93	91,88	93,75

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,9	77,32	85,45	88,93	91,61	93,66
0,95	77,86	86,52	88,66	92,23	93,84
0,955	78,04	86,07	89,20	92,41	93,75
1	79,29	87,14	89,73	91,96	94,02

$S$  (%) para Amostra de tamanho  $55 \times 55$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	49,38	68,75	79,82	82,95	89,82
0,1	56,16	73,13	84,91	85,54	90,09
0,15	61,96	81,07	86,07	88,66	90,27
0,2	68,30	83,84	87,95	88,93	90,89
0,25	69,29	86,52	89,91	89,82	91,79
0,3	73,21	84,46	90,09	89,64	92,68
0,35	75,89	87,86	89,91	90,36	92,68
0,4	78,13	87,86	90,27	90,36	92,95
0,45	79,02	87,59	91,16	89,73	93,21
0,5	81,07	87,14	91,88	90,09	93,93
0,55	81,25	89,20	93,39	90,36	94,55
0,6	81,88	87,77	93,48	90,45	94,38
0,65	82,50	89,73	92,95	90,98	94,82
0,7	84,20	90,54	93,30	91,43	94,73
0,705	82,41	90,09	93,66	91,34	94,73
0,75	82,23	89,91	93,30	90,80	95,09
0,755	82,32	89,82	93,13	90,89	95,00
0,8	81,43	89,29	93,93	91,07	95,00
0,805	81,96	89,46	93,48	91,07	94,91
0,85	82,68	89,29	93,21	91,07	95,09
0,855	83,48	89,29	93,66	91,25	95,09
0,9	82,32	88,93	92,95	90,80	95,00
0,95	83,84	89,38	92,77	91,34	95,09
0,955	84,02	89,46	93,21	91,07	95,00
1	83,75	89,46	93,13	91,16	95,36

$S$  (%) para Amostra de tamanho  $60 \times 60$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	56,34	72,14	80,80	85,98	90,71
0,1	62,14	78,93	85,36	89,38	90,80
0,15	68,75	82,23	89,55	90,54	91,96
0,2	73,13	85,80	90,80	91,96	92,50
0,25	75,45	88,21	89,91	91,34	93,21
0,3	79,29	88,93	90,89	92,50	93,84
0,35	80,63	89,20	91,34	93,04	94,11
0,4	82,59	90,71	92,41	92,68	94,29
0,45	82,23	89,20	90,80	92,77	94,91
0,5	82,41	90,00	91,70	92,05	95,00
0,55	85,54	91,43	92,68	92,68	95,27
0,6	85,18	91,52	92,59	93,13	95,18
0,65	86,70	90,63	93,30	93,57	95,54
0,7	86,70	90,63	93,21	93,93	95,45
0,705	88,13	91,07	92,95	93,93	95,36
0,75	86,61	91,25	93,04	93,93	95,36
0,755	85,80	90,98	92,77	93,66	95,36
0,8	84,82	91,96	93,04	93,84	95,18
0,805	85,54	91,61	93,21	93,75	95,27
0,85	84,46	91,43	93,75	93,30	95,09
0,855	84,82	91,25	93,39	93,21	95,18
0,9	85,18	90,54	93,57	93,21	95,27
0,95	86,43	91,61	92,86	93,75	94,91
0,955	85,45	91,79	92,86	93,75	94,91
1	85,09	91,70	93,13	93,84	94,82

$S$  (%) para Amostra de tamanho  $65 \times 65$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	60,00	76,96	84,64	87,05	93,30
0,1	67,14	82,50	87,05	89,20	93,93
0,15	72,95	86,43	90,00	91,34	93,75
0,2	76,79	87,86	90,54	91,96	93,93
0,25	80,00	87,95	91,43	93,57	94,20
0,3	81,16	90,80	92,50	93,04	94,82
0,35	84,91	92,95	92,95	93,66	94,73
0,4	84,64	92,14	93,04	93,84	95,45
0,45	85,71	91,70	92,77	93,48	95,09
0,5	85,71	91,70	92,77	93,75	95,36
0,55	87,23	92,86	94,02	94,91	95,89
0,6	86,52	91,70	93,66	94,73	96,07
0,65	87,59	93,30	94,20	94,73	95,98
0,7	87,86	93,48	94,82	95,45	96,34
0,705	87,68	93,30	94,73	95,36	96,52
0,75	88,84	93,04	94,46	96,16	96,61
0,755	88,39	92,41	94,64	95,89	96,70
0,8	88,48	92,86	94,20	95,80	96,43
0,805	88,04	93,48	94,46	95,98	96,52
0,85	87,86	93,30	94,73	95,36	96,52
0,855	87,68	92,59	94,64	95,36	96,43
0,9	88,66	93,57	94,02	95,54	96,25
0,95	89,38	93,75	94,91	95,71	96,43
0,955	89,20	93,13	94,73	95,63	96,52
1	89,64	93,48	94,64	95,54	96,70

$S$  (%) para Amostra de tamanho  $70 \times 70$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	61,61	81,61	86,52	91,61	95,09
0,1	69,91	86,88	90,54	92,77	95,36
0,15	74,91	88,3	91,96	93,75	95,80
0,2	79,55	90,36	93,04	95,09	95,63
0,25	83,30	91,52	94,11	94,91	96,25
0,3	85,27	92,05	94,46	94,91	96,61
0,35	86,43	93,84	94,38	94,38	96,88
0,4	87,32	94,55	94,64	94,38	96,88
0,45	88,84	93,21	94,73	94,91	96,88
0,5	88,84	93,75	95,54	95,18	97,05
0,55	90,27	93,30	95,09	94,91	97,14
0,6	89,91	93,57	94,64	95,18	97,32
0,65	89,82	93,75	95,00	95,54	97,41
0,7	90,09	94,55	94,55	95,36	97,41
0,705	89,11	94,46	94,11	95,71	97,41
0,75	90,63	94,64	93,93	95,98	97,32
0,755	90,00	94,55	93,93	95,54	97,32
0,8	90,09	94,82	94,11	95,18	96,96
0,805	90,00	94,64	93,75	95,27	97,14
0,85	89,38	94,73	93,93	95,00	97,14
0,855	89,73	94,64	94,11	95,09	97,14
0,9	90,09	95,09	94,11	95,27	97,05
0,95	90,00	95,09	94,29	95,80	97,41
0,955	90,71	94,73	94,11	95,71	97,59
1	90,36	94,91	94,46	95,89	97,68

$S$  (%) para Amostra de tamanho  $75 \times 75$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	71,43	83,66	87,68	93,75	95,09
0,1	75,63	88,04	90,89	94,82	95,98
0,15	78,84	91,16	93,57	94,73	96,88
0,2	82,86	92,23	93,66	95,00	96,79
0,25	84,20	93,66	94,11	95,80	97,05
0,3	89,55	95,27	94,55	96,34	97,14
0,35	89,38	94,64	95,27	96,34	97,14
0,4	90,27	95,18	94,91	96,96	97,68
0,45	89,29	94,91	95,18	96,88	97,59
0,5	89,91	95,98	95,27	96,88	97,86
0,55	91,25	95,80	96,16	97,05	98,04
0,6	91,25	95,80	95,98	97,32	97,95
0,65	92,50	95,27	96,25	97,32	98,13
0,7	91,96	95,45	96,70	97,23	98,30
0,705	92,32	95,18	96,79	97,32	98,13
0,75	92,41	95,89	97,05	97,59	97,95
0,755	92,77	95,71	97,23	97,32	97,95
0,8	92,59	95,80	96,25	97,14	98,13
0,805	92,14	95,54	96,43	97,14	98,30
0,85	92,95	95,45	96,52	97,32	98,21
0,855	92,23	95,09	96,70	97,32	98,13
0,9	92,86	95,18	96,88	97,59	97,95
0,95	92,86	95,45	97,23	97,41	98,21
0,955	92,23	95,27	96,88	97,59	98,21
1	92,14	95,54	96,52	97,59	98,04

$S$  (%) para Amostra de tamanho  $80 \times 80$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	74,82	85,89	90,54	93,57	95,27
0,1	80,80	90,00	92,50	95,27	96,16
0,15	85,09	92,59	94,29	95,36	96,25
0,2	86,52	93,84	94,91	95,54	96,61
0,25	88,75	95,00	95,89	96,52	96,61
0,3	91,16	95,45	96,16	96,70	96,79
0,35	91,61	95,89	96,43	96,79	96,96
0,4	93,04	95,45	95,63	97,05	97,05
0,45	92,32	96,52	96,25	97,68	97,32
0,5	92,86	96,34	95,89	97,50	97,41
0,55	94,73	96,07	96,34	97,68	97,68
0,6	93,84	95,71	96,16	97,68	97,86
0,65	94,46	95,45	96,70	97,50	97,95
0,7	95,18	96,07	96,88	97,41	97,95
0,705	94,73	95,80	96,88	97,41	97,86
0,75	94,82	95,98	96,70	97,50	97,95
0,755	94,82	95,98	96,96	97,41	97,68
0,8	94,11	95,98	96,70	97,77	97,50
0,805	93,84	95,80	96,52	97,86	97,68
0,85	94,82	95,89	96,79	97,59	97,77
0,855	94,64	95,89	96,79	97,59	97,77
0,9	94,38	95,98	96,43	97,32	97,68
0,95	94,82	96,07	96,25	97,41	97,77
0,955	94,73	95,80	96,16	97,41	97,59
1	95,09	96,07	96,34	97,50	98,04

$S$  (%) para Amostra de tamanho  $85 \times 85$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	74,46	88,39	92,05	93,75	95,80
0,1	81,16	92,32	94,46	95,36	96,61
0,15	84,29	93,30	94,91	95,71	97,05
0,2	87,32	94,46	96,07	95,63	96,88
0,25	90,63	95,27	96,16	96,61	96,88
0,3	91,25	95,45	97,14	96,16	97,32
0,35	91,96	96,16	97,05	96,34	97,41
0,4	93,21	96,70	97,41	96,52	97,59
0,45	93,66	96,34	97,59	96,16	97,68
0,5	92,95	95,98	97,50	96,70	97,95
0,55	94,82	96,96	97,41	96,70	97,86
0,6	94,38	96,70	97,68	96,43	98,21
0,65	94,02	96,61	97,77	96,96	98,39
0,7	94,64	96,25	97,59	97,41	98,13
0,705	94,82	96,52	97,86	97,41	98,21
0,75	94,46	96,70	97,41	97,32	98,39
0,755	94,82	96,79	97,50	97,50	98,30
0,8	93,13	96,25	97,50	97,50	98,13
0,805	93,21	96,25	97,50	97,41	98,13
0,85	93,93	96,61	97,23	97,23	98,13
0,855	93,84	96,61	97,32	97,23	97,77
0,9	94,38	96,70	97,41	97,50	97,95
0,95	95,18	96,61	97,32	97,68	97,95
0,955	94,91	96,88	97,32	97,86	98,04
1	95,54	96,43	97,32	97,77	98,13

$S$  (%) para Amostra de tamanho  $90 \times 90$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	79,55	90,09	91,96	94,11	95,71
0,1	84,55	93,66	95,45	95,71	96,16
0,15	87,95	94,38	96,07	95,98	96,34
0,2	90,36	95,63	97,68	96,70	96,61
0,25	91,88	96,88	97,23	97,05	97,14
0,3	92,05	97,05	97,23	97,86	97,41
0,35	93,66	96,88	97,32	97,14	97,41
0,4	93,75	96,52	97,05	97,50	97,68
0,45	93,93	97,41	96,79	97,41	97,50
0,5	94,20	96,96	97,23	97,59	97,50
0,55	95,54	97,23	97,50	97,59	97,50
0,6	95,98	97,05	97,23	97,68	98,04
0,65	95,36	97,41	97,77	97,77	98,21
0,7	95,27	97,41	97,50	98,04	98,21
0,705	95,18	97,59	97,59	97,86	98,30
0,75	95,63	97,14	97,32	97,59	98,48
0,755	96,25	97,41	97,41	97,59	98,48
0,8	95,36	97,32	97,68	97,68	98,13
0,805	95,18	97,23	97,59	97,86	98,13
0,85	95,27	97,32	97,14	97,86	98,30
0,855	95,18	97,23	97,23	97,86	98,39
0,9	95,89	96,52	97,41	97,95	98,39
0,95	95,45	97,14	97,50	97,95	98,39
0,955	95,18	97,05	97,50	97,86	98,39
1	95,89	96,88	97,32	97,86	98,48

## APÊNDICE F

### SENSIBILIDADE OBTIDA DO MSLMP COM RESPEITO À MATRIZ DE PESOS 4.15

$S$  (%) para Amostra de tamanho  $45 \times 45$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	37,50	57,32	70,18	80,27	87,05
0,1	42,41	63,57	75,54	83,13	87,32
0,15	50,09	67,32	78,21	83,39	89,02
0,2	54,20	70,27	80,45	84,20	89,29
0,25	56,88	74,64	81,61	85,18	90,09
0,3	61,88	76,16	82,50	86,34	91,07
0,35	65,71	79,20	83,57	86,43	90,54
0,4	67,86	78,13	83,21	87,05	90,98
0,45	68,21	80,45	84,02	87,05	91,43
0,5	69,38	80,00	83,66	87,23	91,25
0,55	71,16	79,82	85,09	88,30	91,43
0,6	70,63	78,66	84,91	87,77	91,61
0,65	73,13	79,82	86,43	87,86	91,88
0,7	73,57	81,25	85,18	87,95	91,70
0,705	73,39	81,61	85,45	87,86	91,88
0,75	73,30	79,82	84,91	87,50	91,61
0,755	72,86	79,91	84,82	87,41	91,25

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,8	73,30	80,18	85,36	87,59	91,43
0,805	73,66	81,16	85,09	87,68	90,80
0,85	72,50	80,45	84,46	87,86	91,25
0,855	72,95	80,89	84,82	87,59	91,07
0,9	72,41	80,89	85,09	87,41	91,07
0,95	75,45	80,00	84,73	88,04	91,96
0,955	75,18	79,73	84,55	88,04	91,96
1	74,20	81,88	85,80	88,30	92,14

$S$  (%) para Amostra de tamanho  $50 \times 50$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	40,36	62,23	75,63	81,07	87,95
0,1	45,89	66,79	79,20	83,48	89,46
0,15	52,68	73,39	82,32	86,61	88,66
0,2	55,89	77,23	85,00	88,30	89,29
0,25	63,30	79,73	85,89	87,95	90,54
0,3	67,32	82,95	87,41	88,21	90,45
0,35	69,64	83,84	86,61	87,77	90,98
0,4	70,18	83,21	87,86	88,75	91,61
0,45	73,21	83,57	88,30	88,66	92,05
0,5	72,50	84,82	88,04	89,29	92,95
0,55	76,70	86,16	89,73	90,36	93,39
0,6	74,82	86,88	89,29	90,18	93,57
0,65	77,86	86,34	90,45	91,16	93,57
0,7	76,07	86,61	89,55	91,07	93,84
0,705	76,34	87,14	90,09	91,07	93,75
0,75	78,93	87,59	89,64	90,71	93,75
0,755	78,21	87,05	89,91	90,45	93,66
0,8	76,43	86,52	88,75	91,07	93,57
0,805	78,57	86,61	88,39	90,80	93,57
0,85	76,70	86,61	89,91	90,27	93,04
0,855	77,86	87,23	89,29	90,54	92,95

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,9	77,32	86,43	88,48	90,8	92,68
0,95	77,86	85,63	88,93	91,25	93,93
0,955	78,04	85,98	89,11	91,16	93,75
1	79,29	86,88	89,38	91,61	94,02

S (%) para Amostra de tamanho  $55 \times 55$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	49,38	68,30	81,70	83,30	88,93
0,1	56,16	73,75	86,34	86,96	89,73
0,15	61,96	80,45	87,95	88,04	89,82
0,2	68,30	81,79	89,46	89,46	90,45
0,25	69,29	84,29	91,34	89,29	91,79
0,3	73,21	86,52	91,07	90,89	93,21
0,35	75,89	85,98	91,25	90,27	93,13
0,4	78,13	86,52	91,34	90,98	92,77
0,45	79,02	87,95	92,14	90,54	93,21
0,5	81,07	86,79	91,16	91,07	93,75
0,55	81,25	89,20	92,86	92,14	93,75
0,6	81,88	88,75	93,21	91,96	93,84
0,65	82,50	89,29	93,30	92,23	94,73
0,7	84,20	89,46	93,21	92,41	95,09
0,705	82,41	89,38	93,75	91,79	95,09
0,75	82,23	88,84	93,48	92,14	94,82
0,755	82,32	88,66	93,13	91,70	94,82
0,8	81,43	87,77	92,32	91,79	94,55
0,805	81,96	88,48	92,68	91,79	94,64
0,85	82,68	88,30	92,95	92,23	94,55
0,855	83,48	88,39	92,95	91,79	94,46
0,9	82,32	88,93	91,96	91,70	94,38
0,95	83,84	88,21	92,50	91,70	94,91
0,955	84,02	88,57	92,59	91,79	95,00
1	83,75	87,50	92,77	91,34	94,91

$S$  (%) para Amostra de tamanho  $60 \times 60$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	56,34	73,75	82,41	86,34	90,18
0,1	62,14	78,39	86,25	88,93	90,63
0,15	68,75	83,21	88,66	90,54	91,52
0,2	73,13	86,79	89,91	91,70	92,05
0,25	75,45	86,70	90,54	92,14	92,86
0,3	79,29	88,84	90,89	93,13	93,66
0,35	80,63	89,55	90,71	92,86	93,57
0,4	82,59	88,57	91,16	91,96	94,55
0,45	82,23	89,91	90,71	92,77	94,55
0,5	82,41	89,46	90,98	93,57	94,73
0,55	85,54	90,63	91,43	93,21	94,91
0,6	85,18	90,45	92,59	93,13	95,36
0,65	86,70	90,89	93,04	93,66	95,36
0,7	86,70	90,98	92,95	94,20	95,54
0,705	88,13	91,16	93,21	94,11	95,45
0,75	86,61	90,98	92,68	94,20	95,54
0,755	85,80	90,80	92,68	94,20	95,18
0,8	84,82	90,36	92,68	93,57	95,36
0,805	85,54	90,54	92,50	93,84	95,36
0,85	84,46	90,00	92,50	93,66	95,09
0,855	84,82	90,36	92,50	93,66	95,27
0,9	85,18	89,64	93,21	93,48	95,27
0,95	86,43	90,89	93,39	93,39	95,63
0,955	85,45	90,36	93,30	93,57	95,45
1	85,09	89,91	93,30	93,84	95,45

$S$  (%) para Amostra de tamanho  $65 \times 65$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	60,00	77,95	85,00	87,14	93,04
0,1	67,14	83,93	88,66	89,73	93,93
0,15	72,95	85,63	90,71	91,79	93,57
0,2	76,79	87,68	90,89	92,68	94,20
0,25	80,00	88,30	90,89	92,86	94,64
0,3	81,16	90,27	92,86	93,57	95,54
0,35	84,91	91,61	92,86	93,84	95,18
0,4	84,64	92,50	93,66	93,66	95,18
0,45	85,71	91,52	93,13	93,57	95,45
0,5	85,71	91,16	92,77	93,21	95,80
0,55	87,23	92,05	93,48	94,38	95,63
0,6	86,52	91,70	94,11	93,84	96,16
0,65	87,59	93,21	93,39	94,20	95,98
0,7	87,86	93,04	93,84	94,46	96,34
0,705	87,68	92,77	93,84	94,38	96,34
0,75	88,84	92,77	93,66	94,55	96,16
0,755	88,39	92,14	93,48	94,55	96,16
0,8	88,48	93,13	92,95	94,46	96,34
0,805	88,04	92,68	93,21	94,46	96,34
0,85	87,86	92,41	93,93	94,55	96,16
0,855	87,68	92,50	93,93	94,46	96,16
0,9	88,66	92,95	93,57	94,46	96,07
0,95	89,38	92,95	94,73	95,45	96,43
0,955	89,20	92,86	94,82	95,27	96,52
1	89,64	92,77	94,46	95,27	96,52

$S$  (%) para Amostra de tamanho  $70 \times 70$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	61,61	82,41	87,05	90,36	95,00
0,1	69,91	84,38	91,07	92,86	95,18
0,15	74,91	89,20	91,96	94,82	95,00
0,2	79,55	89,02	93,04	94,73	95,09
0,25	83,30	91,43	93,39	94,20	95,54
0,3	85,27	91,61	93,93	95,27	96,43
0,35	86,43	92,77	94,46	95,00	96,61
0,4	87,32	93,48	94,11	95,00	96,70
0,45	88,84	91,61	93,93	94,91	96,52
0,5	88,84	93,21	94,02	95,18	96,61
0,55	90,27	93,48	94,55	95,80	96,88
0,6	89,91	93,57	93,84	95,80	96,88
0,65	89,82	94,64	94,11	95,89	97,14
0,7	90,09	94,82	94,29	95,36	97,05
0,705	89,11	95,00	94,02	95,27	97,23
0,75	90,63	94,20	94,38	95,80	97,41
0,755	90,00	94,29	94,29	95,63	97,32
0,8	90,09	94,11	93,57	95,00	96,88
0,805	90,00	94,73	93,75	95,36	96,88
0,85	89,38	94,38	93,93	95,18	97,05
0,855	89,73	94,46	94,20	94,91	96,96
0,9	90,09	94,55	94,20	95,00	96,88
0,95	90,00	94,82	93,93	95,36	96,96
0,955	90,71	94,64	94,11	95,27	96,96
1	90,36	94,64	94,64	95,27	97,23

$S$  (%) para Amostra de tamanho  $75 \times 75$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	71,43	83,75	87,86	93,13	95,09
0,1	75,63	88,13	91,79	95,54	96,07
0,15	78,84	91,07	93,21	95,27	96,61
0,2	82,86	92,77	94,11	95,98	96,79
0,25	84,20	94,02	94,73	96,52	97,32
0,3	89,55	95,36	94,55	96,43	97,77
0,35	89,38	94,73	95,27	97,14	97,68
0,4	90,27	95,27	94,82	96,79	97,95
0,45	89,29	95,63	94,20	97,50	97,50
0,5	89,91	95,71	95,00	97,41	97,77
0,55	91,25	96,34	96,34	97,77	97,77
0,6	91,25	95,71	95,89	97,50	97,68
0,65	92,50	95,80	95,71	97,95	98,13
0,7	91,96	95,54	96,43	97,77	98,21
0,705	92,32	95,54	96,34	97,86	98,21
0,75	92,41	95,63	96,34	97,41	97,95
0,755	92,77	96,25	96,43	97,50	97,95
0,8	92,59	95,45	95,98	97,23	98,21
0,805	92,14	95,36	95,98	97,14	98,30
0,85	92,95	95,63	95,89	97,23	98,30
0,855	92,23	95,27	96,07	97,23	98,30
0,9	92,86	95,45	96,25	97,23	98,21
0,95	92,86	95,63	96,25	97,41	98,30
0,955	92,23	95,54	96,25	97,32	98,30
1	92,14	95,54	96,43	97,23	98,04

$S$  (%) para Amostra de tamanho  $80 \times 80$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	74,82	86,16	90,36	92,77	95,09
0,1	80,80	90,27	93,57	94,64	96,25
0,15	85,09	92,32	95,45	94,91	96,07
0,2	86,52	93,66	96,07	96,43	96,70
0,25	88,75	94,55	95,89	96,16	96,70
0,3	91,16	94,46	95,98	96,34	97,05
0,35	91,61	95,27	96,07	96,70	97,41
0,4	93,04	95,54	96,07	96,61	97,59
0,45	92,32	95,80	95,71	96,88	97,86
0,5	92,86	95,89	95,98	96,70	97,68
0,55	94,73	96,16	95,98	97,59	97,86
0,6	93,84	95,36	96,16	97,23	98,04
0,65	94,46	95,89	96,34	97,32	97,86
0,7	95,18	95,80	96,88	97,23	97,86
0,705	94,73	95,98	96,88	97,41	97,95
0,75	94,82	95,89	96,88	97,50	97,95
0,755	94,82	95,71	96,96	97,50	98,04
0,8	94,11	95,80	96,52	97,50	97,77
0,805	93,84	96,07	96,61	97,41	97,86
0,85	94,82	96,07	96,79	97,14	97,86
0,855	94,64	96,07	96,79	97,41	97,77
0,9	94,38	96,16	96,43	97,32	97,50
0,95	94,82	96,43	96,88	97,50	97,68
0,955	94,73	96,34	96,96	97,50	97,68
1	95,09	96,34	96,96	97,41	97,95

$S$  (%) para Amostra de tamanho  $85 \times 85$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	74,46	87,59	92,32	94,29	96,07
0,1	81,16	92,68	94,38	95,45	96,52
0,15	84,29	93,39	95,18	95,36	96,79
0,2	87,32	94,82	96,52	96,16	97,41
0,25	90,63	95,27	96,43	96,07	97,23
0,3	91,25	95,98	97,32	96,43	97,32
0,35	91,96	95,54	97,05	96,43	97,50
0,4	93,21	96,16	96,16	96,25	97,59
0,45	93,66	96,07	96,79	96,43	97,86
0,5	92,95	95,80	96,52	96,43	97,86
0,55	94,82	96,43	97,23	96,43	97,77
0,6	94,38	96,16	96,61	96,61	98,13
0,65	94,02	97,14	97,23	96,70	98,04
0,7	94,64	96,07	97,14	96,88	98,13
0,705	94,82	96,07	96,96	96,88	97,95
0,75	94,46	96,61	97,14	97,05	98,30
0,755	94,82	96,34	96,88	96,96	98,21
0,8	93,13	96,25	97,23	96,96	98,21
0,805	93,21	96,25	97,14	96,96	98,13
0,85	93,93	96,25	97,41	96,88	98,04
0,855	93,84	96,61	97,32	96,88	98,13
0,9	94,38	96,25	97,41	96,79	97,95
0,95	95,18	96,70	97,14	97,23	98,13
0,955	94,91	96,79	97,32	97,23	98,04
1	95,54	95,98	97,41	97,14	98,30

$S$  (%) para Amostra de tamanho  $90 \times 90$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	79,55	91,88	92,59	94,38	95,09
0,1	84,55	93,39	95,80	95,98	95,98
0,15	87,95	94,64	96,43	96,34	96,07
0,2	90,36	95,18	97,32	97,14	96,88
0,25	91,88	96,16	97,59	96,79	96,96
0,3	92,05	96,88	96,96	97,50	97,50
0,35	93,66	97,32	97,23	97,59	97,50
0,4	93,75	96,96	96,70	96,88	97,59
0,45	93,93	97,05	96,88	97,50	97,32
0,5	94,20	97,05	97,50	97,50	97,41
0,55	95,54	97,59	97,59	97,86	97,86
0,6	95,98	97,41	96,96	97,59	97,86
0,65	95,36	97,77	96,96	97,59	98,04
0,7	95,27	97,59	97,14	97,77	98,21
0,705	95,18	97,50	97,32	97,86	98,13
0,75	95,63	97,32	97,23	97,77	98,21
0,755	96,25	96,88	97,32	97,50	98,21
0,8	95,36	96,61	97,23	97,68	98,13
0,805	95,18	96,70	97,23	97,86	98,13
0,85	95,27	97,23	97,23	97,68	98,21
0,855	95,18	96,88	97,32	97,77	98,21
0,9	95,89	96,52	96,96	97,59	98,30
0,95	95,45	96,61	97,14	97,68	98,13
0,955	95,18	96,70	97,23	97,77	98,30
1	95,89	96,52	97,23	97,77	98,21

## APÊNDICE G

### SENSIBILIDADE OBTIDA DO MSLMP COM RESPEITO À MATRIZ DE PESOS 4.16

$S$  (%) para Amostra de tamanho  $45 \times 45$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	37,50	49,38	65,09	78,39	86,61
0,1	42,41	55,09	68,13	78,30	86,52
0,15	50,09	57,68	71,43	79,20	86,79
0,2	54,20	60,45	72,95	82,32	86,34
0,25	56,88	66,34	74,11	81,34	86,70
0,3	61,88	68,57	77,32	81,70	85,63
0,35	65,71	71,34	78,39	83,21	87,95
0,4	67,86	70,89	76,25	85,63	88,84
0,45	68,21	73,30	80,45	84,46	87,23
0,5	69,38	75,45	81,25	85,18	89,20
0,55	71,16	75,09	80,80	85,45	88,57
0,6	70,63	74,38	83,66	86,25	88,13
0,65	73,13	75,89	82,68	88,30	89,02
0,7	73,57	77,50	83,57	87,23	88,57
0,705	73,39	76,07	82,50	87,59	88,66
0,75	73,30	76,61	83,48	87,86	88,57
0,755	72,86	76,43	83,66	87,59	89,20

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,8	73,30	75,36	83,13	87,50	89,64
0,805	73,66	77,05	82,32	87,59	89,38
0,85	72,50	75,71	82,77	87,05	89,73
0,855	72,95	76,61	82,50	87,50	89,73
0,9	72,41	76,96	83,04	87,95	89,11
0,95	75,45	78,30	84,91	88,13	90,36
0,955	75,18	78,57	85,00	88,75	90,45
1	74,20	79,20	84,64	88,66	90,09

$S$  (%) para Amostra de tamanho  $50 \times 50$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	40,36	57,05	70,27	80,45	88,39
0,1	45,89	60,09	73,04	82,77	89,11
0,15	52,68	65,09	76,16	83,66	90,45
0,2	55,89	69,38	78,66	84,55	88,57
0,25	63,30	70,98	79,11	86,61	87,77
0,3	67,32	74,20	81,79	86,07	88,13
0,35	69,64	77,41	82,59	87,32	88,66
0,4	70,18	78,57	83,21	87,77	89,11
0,45	73,21	79,11	84,73	87,77	89,38
0,5	72,50	79,91	84,38	89,02	90,09
0,55	76,70	80,98	85,63	88,48	89,82
0,6	74,82	83,30	83,75	89,38	89,91
0,65	77,86	83,84	86,07	90,80	90,18
0,7	76,07	82,86	86,34	90,98	90,36
0,705	76,34	83,13	86,43	90,54	89,91
0,75	78,93	83,30	87,86	90,45	90,54
0,755	78,21	84,20	87,68	90,00	90,09
0,8	76,43	82,50	88,39	91,16	90,63
0,805	78,57	83,57	88,21	91,16	90,89
0,85	76,70	85,36	87,32	90,63	91,25
0,855	77,86	84,91	86,88	90,18	90,54

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,9	77,32	85,89	87,86	90,45	91,43
0,95	77,86	85,80	87,86	91,52	92,05
0,955	78,04	84,55	87,68	91,88	92,14
1	79,29	85,80	88,57	92,05	92,14

$S$  (%) para Amostra de tamanho  $55 \times 55$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	49,38	64,29	76,88	82,41	89,38
0,1	56,16	68,04	79,02	84,64	91,25
0,15	61,96	71,43	82,05	87,59	90,63
0,2	68,30	75,80	84,38	87,50	90,63
0,25	69,29	78,75	86,96	89,73	90,54
0,3	73,21	79,73	86,70	91,52	89,55
0,35	75,89	81,34	88,57	90,80	89,38
0,4	78,13	81,52	89,55	90,18	90,36
0,45	79,02	83,30	88,04	91,88	91,16
0,5	81,07	83,13	89,11	91,34	91,52
0,55	81,25	86,07	89,73	92,86	91,43
0,6	81,88	84,38	90,54	92,68	90,89
0,65	82,50	85,45	92,41	93,75	92,41
0,7	84,20	87,68	92,77	93,66	93,39
0,705	82,41	86,61	92,59	93,13	93,39
0,75	82,23	85,98	92,50	93,30	93,48
0,755	82,32	85,63	92,68	92,41	93,57
0,8	81,43	86,61	91,07	92,77	93,21
0,805	81,96	85,80	91,16	93,39	93,57
0,85	82,68	86,16	91,52	92,86	93,84
0,855	83,48	87,05	91,61	92,59	93,84
0,9	82,32	87,14	91,07	93,75	93,66
0,95	83,84	87,68	92,50	93,84	94,46
0,955	84,02	87,68	91,43	93,75	94,55
1	83,75	88,04	92,41	93,93	94,73

$S$  (%) para Amostra de tamanho  $60 \times 60$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	56,34	68,04	80,71	86,7	91,43
0,1	62,14	71,43	81,61	90,00	90,71
0,15	68,75	74,46	84,02	89,11	91,34
0,2	73,13	79,64	85,63	91,25	92,68
0,25	75,45	82,86	88,13	91,25	92,32
0,3	79,29	82,95	88,13	92,14	94,38
0,35	80,63	85,63	89,64	91,52	94,46
0,4	82,59	86,25	90,54	93,13	94,02
0,45	82,23	87,68	90,89	93,48	93,57
0,5	82,41	87,14	89,91	93,84	93,93
0,55	85,54	87,95	92,23	93,84	94,29
0,6	85,18	89,02	92,68	93,84	94,38
0,65	86,70	89,46	93,21	94,29	95,27
0,7	86,70	89,64	93,93	94,02	95,18
0,705	88,13	89,46	93,48	94,38	94,82
0,75	86,61	89,38	93,75	94,55	95,36
0,755	85,80	89,64	93,75	93,84	95,54
0,8	84,82	89,38	93,75	94,82	95,45
0,805	85,54	89,38	93,57	94,82	95,45
0,85	84,46	90,09	92,86	94,55	95,54
0,855	84,82	90,45	92,32	95,27	95,36
0,9	85,18	89,82	93,04	94,82	95,98
0,95	86,43	90,80	93,66	95,27	96,16
0,955	85,45	90,89	93,57	95,54	96,16
1	85,09	91,43	94,11	95,45	95,89

$S$  (%) para Amostra de tamanho  $65 \times 65$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	60,00	74,29	84,02	88,13	92,86
0,1	67,14	78,39	86,34	90,00	94,02
0,15	72,95	79,82	88,13	91,61	94,29
0,2	76,79	83,57	87,32	91,61	94,73
0,25	80,00	85,00	90,09	93,66	94,91
0,3	81,16	86,61	91,16	93,13	94,64
0,35	84,91	88,66	90,98	94,91	95,00
0,4	84,64	89,20	91,52	94,11	95,18
0,45	85,71	89,20	91,16	95,00	95,71
0,5	85,71	88,84	93,21	94,11	96,34
0,55	87,23	90,80	93,66	95,00	95,80
0,6	86,52	90,36	93,21	95,71	95,98
0,65	87,59	92,77	93,39	95,54	96,61
0,7	87,86	92,59	94,29	95,71	96,70
0,705	87,68	92,32	94,82	95,36	96,43
0,75	88,84	92,77	94,64	95,63	96,96
0,755	88,39	92,59	93,84	95,98	96,61
0,8	88,48	91,88	93,93	96,07	96,70
0,805	88,04	91,70	94,38	96,07	96,34
0,85	87,86	91,16	95,18	96,25	96,70
0,855	87,68	90,98	95,27	96,16	97,05
0,9	88,66	92,50	94,82	95,89	97,23
0,95	89,38	92,95	95,80	96,61	97,05
0,955	89,20	92,86	95,27	96,52	97,32
1	89,64	92,95	95,54	96,34	97,50

$S$  (%) para Amostra de tamanho  $70 \times 70$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	61,61	79,29	85,71	90,71	95,63
0,1	69,91	79,38	88,39	92,68	95,00
0,15	74,91	84,11	90,18	92,77	95,36
0,2	79,55	86,79	90,89	94,20	95,80
0,25	83,30	87,86	92,68	95,09	96,43
0,3	85,27	88,13	92,86	96,07	97,05
0,35	86,43	90,89	92,59	96,25	97,23
0,4	87,32	90,80	94,46	95,71	97,41
0,45	88,84	90,89	94,38	96,16	96,96
0,5	88,84	91,52	94,73	96,88	97,23
0,55	90,27	91,52	95,27	97,23	97,23
0,6	89,91	91,70	94,73	97,14	96,88
0,65	89,82	92,86	95,54	97,41	97,68
0,7	90,09	93,13	95,63	97,05	97,59
0,705	89,11	94,11	95,71	96,88	97,14
0,75	90,63	93,93	96,07	97,41	97,41
0,755	90,00	93,75	96,34	97,68	97,41
0,8	90,09	93,30	95,63	96,79	97,77
0,805	90,00	93,39	95,45	97,23	97,50
0,85	89,38	93,39	95,54	97,59	97,14
0,855	89,73	93,39	94,82	97,68	97,32
0,9	90,09	93,75	95,09	97,14	97,32
0,95	90,00	94,55	95,89	97,95	97,59
0,955	90,71	94,55	95,63	97,95	97,41
1	90,36	95,27	96,34	97,23	97,68

$S$  (%) para Amostra de tamanho  $75 \times 75$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	71,43	80,63	87,77	93,21	95,54
0,1	75,63	84,46	90,36	94,38	96,61
0,15	78,84	87,77	91,79	95,45	96,43
0,2	82,86	89,46	92,68	95,63	97,23
0,25	84,20	91,34	94,20	96,16	97,05
0,3	89,55	91,70	94,38	97,32	97,86
0,35	89,38	93,66	94,64	97,23	97,95
0,4	90,27	93,21	94,11	97,86	97,59
0,45	89,29	94,11	95,18	97,86	97,68
0,5	89,91	94,73	93,93	97,59	97,32
0,55	91,25	94,82	95,36	97,50	97,41
0,6	91,25	95,27	95,45	98,39	97,68
0,65	92,50	95,80	95,80	97,77	97,95
0,7	91,96	94,82	96,25	97,95	97,68
0,705	92,32	94,64	96,16	97,95	97,77
0,75	92,41	95,27	96,16	97,59	98,57
0,755	92,77	95,18	95,80	97,68	98,13
0,8	92,59	94,73	95,80	97,95	98,39
0,805	92,14	95,45	96,25	97,95	98,21
0,85	92,95	96,34	96,70	97,68	98,13
0,855	92,23	96,07	96,61	97,95	98,21
0,9	92,86	95,45	96,88	97,68	98,57
0,95	92,86	96,52	96,79	97,95	98,84
0,955	92,23	96,70	96,96	97,95	98,75
1	92,14	96,16	96,52	97,77	99,38

$S$  (%) para Amostra de tamanho  $80 \times 80$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	74,82	81,79	90,00	92,68	95,36
0,1	80,80	87,05	91,52	95,00	96,34
0,15	85,09	89,91	93,84	95,98	96,70
0,2	86,52	90,00	94,29	96,34	97,05
0,25	88,75	93,21	95,27	96,96	96,96
0,3	91,16	92,32	95,45	96,96	97,50
0,35	91,61	94,11	96,16	97,32	97,50
0,4	93,04	94,11	96,43	97,59	96,79
0,45	92,32	94,29	95,63	97,77	97,59
0,5	92,86	95,09	96,61	97,14	97,32
0,55	94,73	95,54	96,70	97,32	97,41
0,6	93,84	94,46	95,89	98,30	97,68
0,65	94,46	95,27	96,88	98,30	97,86
0,7	95,18	95,27	97,05	98,13	97,68
0,705	94,73	96,25	97,14	97,86	97,68
0,75	94,82	96,79	96,96	97,95	98,13
0,755	94,82	96,61	97,14	98,13	97,95
0,8	94,11	96,16	97,05	98,13	98,21
0,805	93,84	95,89	96,61	98,04	98,13
0,85	94,82	96,52	96,96	97,50	98,21
0,855	94,64	96,25	97,05	97,95	98,13
0,9	94,38	96,79	97,05	97,77	98,21
0,95	94,82	96,43	97,50	98,57	98,30
0,955	94,73	96,61	97,32	98,30	98,48
1	95,09	96,96	96,79	98,13	98,66

$S$  (%) para Amostra de tamanho  $85 \times 85$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	74,46	85,45	92,14	91,96	95,98
0,1	81,16	89,64	93,13	94,20	97,50
0,15	84,29	90,63	93,48	95,18	97,59
0,2	87,32	90,89	94,11	96,25	97,86
0,25	90,63	93,13	95,71	96,16	97,95
0,3	91,25	94,46	97,05	96,43	98,21
0,35	91,96	96,34	97,32	97,05	97,86
0,4	93,21	95,27	96,34	97,23	97,50
0,45	93,66	95,89	96,96	97,95	97,59
0,5	92,95	95,27	97,32	97,50	97,77
0,55	94,82	96,34	97,50	98,48	98,21
0,6	94,38	96,70	97,59	98,30	98,21
0,65	94,02	96,79	97,77	98,30	98,13
0,7	94,64	96,25	98,21	98,13	98,48
0,705	94,82	96,43	98,04	98,39	98,39
0,75	94,46	96,88	98,39	98,48	98,48
0,755	94,82	96,43	98,39	98,39	98,39
0,8	93,13	95,89	97,86	97,77	98,48
0,805	93,21	95,89	98,04	97,86	98,30
0,85	93,93	96,43	98,04	97,95	98,48
0,855	93,84	96,16	98,13	98,04	98,48
0,9	94,38	96,43	98,21	98,48	98,75
0,95	95,18	97,05	98,13	98,30	98,93
0,955	94,91	97,23	98,04	98,39	98,93
1	95,54	97,05	97,95	98,66	99,02

$S$  (%) para Amostra de tamanho  $90 \times 90$

$\lambda$	MSLMP_1	MSLMP_2	MSLMP_3	MSLMP_4	MSLMP_5
0,05	79,55	88,57	91,61	94,55	96,96
0,1	84,55	90,89	94,29	95,54	97,23
0,15	87,95	90,98	95,45	96,07	97,59
0,2	90,36	94,02	96,16	97,05	97,59
0,25	91,88	94,55	96,96	97,32	97,77
0,3	92,05	94,73	97,59	97,68	97,95
0,35	93,66	96,43	97,41	97,95	98,39
0,4	93,75	97,14	97,59	98,39	98,66
0,45	93,93	96,52	97,50	98,75	98,30
0,5	94,20	96,25	97,59	98,21	98,04
0,55	95,54	96,43	98,04	98,13	98,57
0,6	95,98	97,14	97,59	98,48	98,48
0,65	95,36	97,32	97,68	98,48	98,66
0,7	95,27	97,59	98,04	98,57	99,11
0,705	95,18	97,68	98,13	98,48	99,11
0,75	95,63	97,59	98,13	98,75	99,02
0,755	96,25	97,14	98,13	98,75	98,93
0,8	95,36	96,88	98,21	98,84	98,84
0,805	95,18	96,43	98,21	98,66	98,66
0,85	95,27	97,32	98,04	98,84	98,84
0,855	95,18	97,14	97,68	98,75	98,57
0,9	95,89	97,41	98,30	99,02	98,84
0,95	95,45	97,32	97,86	99,20	98,84
0,955	95,18	97,50	97,86	99,02	98,84
1	95,89	97,14	98,39	99,11	98,84

## TERMO DE REPRODUÇÃO XEROGRÁFICA

Autorizo a reprodução xerográfica do presente Trabalho de Conclusão, na íntegra ou em partes, para fins de pesquisa.

São José do Rio Preto, 31 de Março de 2016.

---

María Jacqueline Atoche Bravo